

UNIVERSIDADE FEDERAL DO PARANÁ

JOÃO HENRIQUE BECKER

**REGISTRO DE NUVENS DE PONTOS PROVENIENTES DE CÂMERA DE
DISTÂNCIA**

CURITIBA

2014

JOÃO HENRIQUE BECKER

**REGISTRO DE NUVENS DE PONTOS PROVENIENTES DE CÂMERA DE
DISTÂNCIA**

Dissertação apresentada ao Curso de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná, como requisito parcial para obtenção do grau de Mestre em Ciências Geodésicas.

**Orientador: Prof. Dr. Jorge Antonio
Silva Centeno**

**CURITIBA
2014**

Becker, João Henrique

Registro de nuvens de pontos provenientes de câmera de distância / João Henrique Becker. – Curitiba, 2014.

76 f. : il.; tabs.

Dissertação (mestrado) – Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas.

Orientador: Jorge Antonio Silva Centeno

Bibliografia: p. 73-76

1. Distâncias - Medição. 2. Fotografias espaciais. 3. Levantamentos eletrônicos. I. Centeno, Jorge Antonio Silva. II. Título.

CDD 526.3

TERMO DE APROVAÇÃO

JOÃO HENRIQUE BECKER


"REGISTRO DE NUVENS DE PONTOS PROVENIENTES DE CÂMERA DE DISTÂNCIA"

Dissertação nº 274 aprovada como requisito parcial do grau de Mestre no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

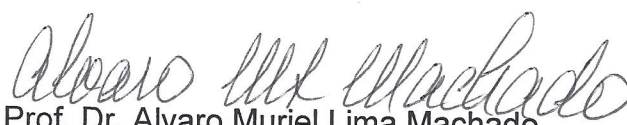
Orientador:



Prof. Dr. Jorge Antonio Silva Centeno
Departamento de Geomática, UFPR



Prof. Dr. Alex Soria Medina
Departamento de Geomática, UFPR



Prof. Dr. Alvaro Muriel Lima Machado
Departamento de Geomática, UFPR

Curitiba, 22 de agosto de 2014.

RESUMO

As câmeras de distância são equipamentos relativamente novos, que utilizam o princípio do ToF (*Time-of-Flight*) para medição de distâncias. Sua utilização já é bastante difundida para aplicações envolvendo detecção de movimento ou orientação de máquinas e robôs, porém poucos estudos buscando sua aplicação para levantamentos tridimensionais são realizados. Devido à forma como os dados são adquiridos com este sensor, diversas nuvens devem ser obtidas e então unificadas através de um processo de registro geométrico para a representação de uma cena completa. Com o objetivo de saber a qualidade de uma nuvem obtida por este processo com este tipo de sensor, nuvens de pontos geradas a partir das imagens de distância foram unidas utilizando o método do ICP (*Iterative Closest Point*) e comparadas a uma nuvem obtida por *laser scanner*, que possui uma precisão maior do que a da câmera de distância. Durante o trabalho, notou-se o acúmulo de distorções e ruídos nas nuvens obtidas com a câmera de distância, devido às suas propriedades e sua forma de funcionamento. Apesar disso, os resultados obtidos mostram que o processo de registro utilizado alcança um alinhamento adequado, apesar de certas discrepâncias, devido, principalmente, a tais distorções acumuladas das nuvens.

Palavras-chave: Câmera de distância, Time-of-Flight, Registro geométrico, ICP

ABSTRACT

Range Cameras are a fairly recent type of equipment to measure 3D points and utilize the Time-of-Flight principle to measure distances. It is already well known for applications such as movement detection and machinery and robot orientation, however fewer studies are done seeking for optimizations in its usage for 3D surveys. Due to the data acquisition format, several clouds unified by a registration process are needed in order to represent a full scene of interest. Willing to know the quality of a 3D cloud obtained using such process for this kind of sensor, several point clouds derived from the range images were united using the Iterative Closest Point registration method and compared to a point cloud obtained using a laser scanner sensor. During this process, distortion and noise heaps were noticed from the clouds generated by the range images, mostly because of the range camera working principles. Still, the final results show that the registration process used achieves good results, as most of the unconformities found were due to the distortion heap from the clouds.

Keywords: Range camera, Time-of-Flight, Geometric registration, Iterative Closest Point

LISTA DE ABREVIATURAS E SIGLAS

DARGES	- <i>Data Aligned Rigid Constrained Exhaustive Search</i>
FPFH	- <i>Fast Point Feature Histogram</i>
FPS	- <i>Frames Per Second</i>
GNSS	- <i>Global Navigation Satellite System</i>
ICP	- <i>Iterative Closest Point</i>
LASER	- <i>Light Amplification by Stimulated Emission of Radiation</i>
NDT	- <i>Normal Distributions Transform</i>
PCL	- <i>Point Cloud Library</i>
PFH	- <i>Point Feature Histogram</i>
PMD	- <i>Photonic Mixer Device</i>
RANSAC	- <i>Random Sample Consensus</i>
SAC-IA	- <i>Sample Consensus - Initial Alignment</i>
SPFH	- <i>Simple Point Feature Histograms</i>
TOF	- <i>Time of Flight</i>

LISTA DE ILUSTRAÇÕES

FIGURA 1 - TIPOS DE IMAGENS GERADAS PELA CÂMERA PMD CAMCUBE.	19
FIGURA 2 - COLINERIDADE ENTRE OS PONTOS.	19
FIGURA 3 - PONTOS VIZINHOS UTILIZADOS PARA O CALCULO DO PFH.	41
FIGURA 4 - PONTOS VIZINHOS UTILIZADOS PARA O CALCULO DO FPFH.	42
FIGURA 5 – FLUXOGRAMA DAS ETAPAS REALIZADAS	44
FIGURA 6 - REGISTRO DE DUAS NUVENS. A NUVEM EM AZUL É A NUVEM A SER REGISTRADA, A NUVEM EM VERMELHO É A NUVEM COM APENAS METADE DO QUADRO PARA O PRIMEIRO ALINHAMENTO. E A NUVEM EM VERDE, A NUVEM DE DESTINO.	45
FIGURA 7 - ETAPA DE FILTRAGEM PARA A REMOÇÃO DE RUÍDOS.	46
FIGURA 8 - DEMONSTRAÇÃO DAS METADES DA NUVEM GERADAS.	49
FIGURA 9 - REPRESENTAÇÃO DA SALA UTILIZANDO AS 58 NUVENS.	51
FIGURA 10 - FOTO RECENTE DA SALA LEVANTADA	52
FIGURA 11 - VISTA SUPERIOR DA REPRESENTAÇÃO DA SALA COM AS 58 NUVENS PARA VISUALIZAÇÃO DO ERRO DE FECHAMENTO.	53
FIGURA 12 - PRESENÇA DE DISTORÇÕES INDICADAS PELA COMPARAÇÃO A UMA LINHA RETA.	53
FIGURA 13 - IMAGEM DA SALA LEVANTADA	54
FIGURA 14 – ESQUEMA DA DISPOSIÇÃO DOS OBJETOS NO LOCAL.	55
FIGURA 15 - VISTA EM PLANTA DO REGISTRO ENTRE DUAS NUVENS DE PONTOS DA CÂMERA. A IMAGEM DA ESQUERDA MOSTRA AS NUVENS ANTES DO REGISTRO, A DA DIREITA APÓS O REGISTRO.	55
FIGURA 16 - VISTA FRONTAL DO RESULTADO DO REGISTRO ENTRE DUAS NUVENS DA CÂMERA.	56
FIGURA 17 - RESULTADO DO REGISTRO COM AS 22 NUVENS DA CÂMERA DE DISTÂNCIA.	56
FIGURA 18 - VISTA EM PLANTA DO REGISTRO FINAL COM AS 22 NUVENS.	57
FIGURA 19 - ACÚMULO DE RUÍDOS DEVIDO À PRESENÇA DE OBJETOS NA CENA.	58
FIGURA 20 - NUVENS COLETADAS COM LASER SCANNER.	59
FIGURA 21 - NUVEM RESULTANTE DO REGISTRO DAS NUVENS <i>LASER SCANNER</i>	59

FIGURA 22 - REGIÃO DE PONTOS REMOVIDA PARA SIMULAR A AUSÊNCIA DE PONTOS.	60
FIGURA 23 - RESULTADO DO REGISTRO ENTRE A NUVEM DA CAMERA E DO <i>LASER SCANNER</i>	61
FIGURA 24 - VISTA EM PLANTA DO RESULTADO DO REGISTRO.	62
FIGURA 25 - NUVEM DA CAMÊRA, COLORIDA DE ACORDO COM AS DISTÂNCIAS.	63
FIGURA 26 - HISTOGRAMA DAS DISTÂNCIAS ENTRE OS PONTOS.	64
FIGURA 27 - REGIÕES UTILIZADA PARA A ANÁLISE PONTO A PLANO.	65

LISTA DE TABELAS

QUADRO 1 – ESPECIFICAÇÕES TÉCNICAS DA CÂMARA PMD CAMCUBE3.0 ..	35
QUADRO 2 - QUANTIDADE DE PONTOS SITUADOS A DIFERENTES DISTÂNCIAS.....	64
QUADRO 3 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 1, 2, 3 E 4.	66
QUADRO 4 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 5 E 6.	66
QUADRO 5 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 7, 8 E 9.	67
QUADRO 6 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 10 E 11.	67
QUADRO 7 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 12 E 13.	68
QUADRO 8 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 1 A 11.	68
QUADRO 9 - DISTÂNCIAS MÉDIAS E DESVIOS-PADRÃO PARA REGIÕES 1 A 6.	69

SUMÁRIO

SUMÁRIO	9
1 INTRODUÇÃO	11
1.1 OBJETIVO GERAL	13
1.2 OBJETIVOS ESPECÍFICOS	13
1.3 JUSTIFICATIVA	14
1.4 ESTRUTURA DA DISSERTAÇÃO	15
2 REVISÃO BIBLIOGRÁFICA	16
2.1 MEDIÇÃO DE DISTÂNCIA PELO PRINCÍPIO TIME-OF-FLIGHT	16
2.1.1 Medição pela diferença de fase de um sinal modulado	17
2.2 GERAÇÃO DE NUVEM DE PONTOS A PARTIR DA IMAGEM DE DISTÂNCIA	19
2.3 REGISTRO GEOMÉTRICO	22
2.3.1 <i>Normal Distributions Transform</i> – NDT	23
2.3.2 <i>Point Signature</i> – Assinatura Pontual	24
2.3.3 <i>Spin Images</i>	25
2.3.4 Análise da componente principal	27
2.3.5 RANSAC-Based DARCES	28
2.3.6 <i>Algebraic Surface Model</i>	29
2.3.7 <i>Line-Based Algorithm</i>	30
2.3.8 Algoritmos Genéticos	31
2.3.9 <i>Iterative Closest Point</i>	32
3 MATERIAIS E MÉTODOS	34
3.1 MATERIAIS UTILIZADOS	34
3.2 <i>ITERATIVE CLOSEST POINT</i> - ICP	35
3.3 ALINHAMENTO PRÉVIO: <i>SAMPLE CONSENSUS INITIAL ALIGNMENT</i>	39
3.3.1 <i>Point Feature Histogram</i> e <i>Fast Point Feature Histogram</i>	39
3.4 ALINHAMENTO PRÉVIO: <i>Alignment Prerejective</i>	42
3.5 PROCEDIMENTOS	44
3.5.1 Pré-análise por regiões	48
3.6 VERIFICAÇÃO DA PRECISÃO	49
4 RESULTADOS	51
4.1 REGISTRO DAS NUVENS DA CÂMERA DE DISTÂNCIA	51
4.1.1 Resultados Iniciais	51
4.1.2 Nuvem gerada para comparação com <i>laser scanner</i>	54

4.2 GERAÇÃO DA NUVEM DE REFERÊNCIA.....	58
4.3 REGISTRO ENTRE CÂMERA E LASER	60
4.4 AVALIAÇÃO DA QUALIDADE DO REGISTRO	62
4.4.1 Distância Ponto a Ponto	62
4.4.2 Distância Entre Planos	65
5 CONCLUSÕES	70
5.1 CONSIDERAÇÕES E RECOMENDAÇÕES	72
REFERÊNCIAS.....	73

1 INTRODUÇÃO

A demanda por informações métricas tridimensionais tem crescido nos últimos anos impulsionando o desenvolvimento de novas ferramentas e métodos para a coleta de dados e informações espaciais. Em se tratando de ambientes externos, a obtenção de dados tridimensionais conta com a disponibilidade de sistemas de varredura a LASER que, apoiados por sistemas de posicionamento GNSS (*Global Navigation Satellite System*) e sistemas inerciais, permitem o cálculo da posição de uma grande e densa nuvem de pontos no espaço.

Tratando-se de ambientes internos, a varredura a LASER ainda mostra-se eficiente, porém também possui algumas limitações. Entre elas, se encontram o tempo necessário para fazer uma varredura, pois apenas um ponto é medido a cada instante, a necessidade de deslocamento do aparelho, pela ocupação de várias estações, e a união das nuvens de pontos para gerar uma única nuvem que represente todo o ambiente. E, ainda assim, a varredura a LASER pode apresentar regiões de oclusão, devido à disposição de objetos presentes ou detalhes arquitetônicos, como pilares, pois um levantamento sem a presença de oclusões pode exigir um elevado número de estações além de um bom planejamento prévio das posições de ocupação.

Uma alternativa é a aplicação de técnicas de Fotogrametria, pois o tempo de levantamento é reduzido. Porém, para a obtenção de informação métrica a partir deste método, sem a utilização de dados adicionais adquiridos por outros sensores ou métodos, é necessária a tomada de pelo menos duas imagens com sobreposição, além da existência de feições visuais distinguíveis para a recessão e interseção espacial.

As câmeras de distância são uma tecnologia relativamente recente e suas características - sensor ativo, captura em quadro, alta taxa de captura - são muito úteis na área da robótica, principalmente para visão de robôs para orientação e prevenção de colisões (WEINGARTEN *et al.*, 2004; DROESCHEL *et al.*, 2010). Porém, devido à sua abertura angular e alcance de medição pequenos, 40°x40° e 7,5 metros, respectivamente, para o modelo PMD CamCube 3.0, a sua aplicação para o levantamento de fachadas e interiores não parece muito interessante em relação a utilização, por exemplo, de um sistema *laser scanner*. A câmera de distância se apresenta, entretanto, como alternativa de menor custo ao *laser*

scanner, preservando suas características, como formato dos dados e o fato de ser um sensor ativo.

Entre as possíveis aplicações destes equipamentos para fins de modelagem tridimensional, pode-se citar o mapeamento de infraestruturas como para a atualização de plantas de fábricas ou aeroportos, que sofrem constantes modificações; patrimônio histórico, como teatros ou prédios históricos; vias de acesso para pedestres, incluindo escadarias e rampas para facilitar a determinação de vias de fuga em situações de emergência e na mineração, para o mapeamento de túneis.

Métodos de registro geométrico tornam possível a utilização desse tipo de sensor para as finalidades supracitadas, pois com sua alta taxa de captura podem-se obter diversas nuvens com grande sobreposição, ao capturar frames com pouca variação angular e pouco deslocamento. Os métodos de registro geométrico podem realizar, então, o registro entre dois conjuntos de pontos, ou duas superfícies. Isso é feito encontrando-se a transformação geométrica ideal entre os dois conjuntos, ou seja, aquela que minimize o erro médio entre eles. Essa transformação é obtida pela correspondência de pontos entre os dois conjuntos, que, por sua vez, pode ser realizada baseando-se em certas características ou propriedades dos pontos.

Além disso, a qualidade final a ser esperada do registro quando utilizadas diversas nuvens de pontos geradas com uma câmera de distância e unidas pelo processo de registro geométrico não é conhecida. Porém, conhecer a qualidade de um produto é crucial para decidir sobre a possibilidade da utilização de um método para dada aplicação. Por isso, é necessário identificar se o registro geométrico das nuvens de pontos gera resultados com qualidade satisfatória para o usuário, bem como as possíveis diferenças de qualidade devido ao uso de diferentes fontes de dados.

1.1 OBJETIVO GERAL

Realizar o registro integrado de nuvens de pontos oriundas de câmera de distância e de sistema LASER de varredura terrestre, com base nos algoritmos *Iterative Closest Point* (ICP), *Sample Consensus Initial Alignment* (SAC-IA) e *Alignment Prerejective*, bem como avaliar a qualidade do registro da nuvem de pontos resultante.

1.2 OBJETIVOS ESPECÍFICOS

- Executar levantamentos de dados usando câmera de distância e sistema LASER de varredura terrestre;
- Identificar diferentes métodos de registro de nuvens de pontos;
- Verificar as condições de pré-alinhamento necessárias para a utilização dos algoritmos de registro de nuvens de pontos;
- Realizar o registro das nuvens de pontos obtidas com a câmera de distância;
- Realizar o registro das nuvens de pontos obtidas com o sistema LASER de varredura terrestre (nuvem resultante adotada como referência);
- Realizar o registro integrado da nuvem resultante da câmera de distância com parte da nuvem de referência, e
- Avaliar a precisão final do processo de registro, em função da nuvem de referência.

1.3 JUSTIFICATIVA

Dados tridimensionais de ambientes internos podem ser obtidos por Fotogrametria convencional, por varredura com *laser scanner* terrestre, ou por câmeras de distância. Atualmente a utilização de *laser scanner* terrestre é a forma mais comum de realizar este tipo de levantamento, devido à qualidade geométrica dos dados fornecidos e a relativa simplicidade para a execução do levantamento utilizando este tipo de sensor, quando na presença de poucas obstruções.

As câmeras de distâncias apresentam algumas vantagens em relação à Fotogrametria convencional e em relação ao *laser scanner*. Em comparação com a Fotogrametria terrestre convencional, os dados oriundos de câmera de distância apresentam a vantagem de não necessitarem de processamento de imagens estereoscópicas. Além disso, por ser um sensor ativo, câmeras de distância não necessitam de iluminação externa para realização de medidas.

Comparando-se os dados obtidos com *laser scanner* e com câmeras de distância, os dados provenientes da varredura a LASER apresentam maior precisão geométrica, entretanto, as câmeras de distância são mais versáteis e de menor custo. Sua versatilidade pode ser evidenciada no caso do levantamento de dados para um ambiente com grande quantidade de obstruções, para o qual diversas estações do *laser scanner* teriam que ser ocupadas para se obter um levantamento completo, sem vazios originados por oclusões.

Os dados obtidos com as câmeras de distância podem ser transformados em nuvens de pontos sem a necessidade de informações de outro sensor. Com os dados de mesma natureza daqueles fornecidos pelo *laser scanner* é possível o uso integrado dos dados entre sensores.

Devido às vantagens supracitadas, este estudo justifica-se pela necessidade de investigação de métodos apropriados para registro de nuvens de pontos, oriundas de câmeras de distância, bem como da análise da precisão alcançada com a aplicação dos mesmos.

1.4 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação é subdividida em cinco capítulos. No presente capítulo, é feita a introdução ao tema abordado, apresentam-se os objetivos e a justificativa da pesquisa. No segundo capítulo é apresentada a revisão de literatura, assim como uma breve revisão de diferentes métodos de registro geométrico. No terceiro capítulo são descritos os materiais utilizados no trabalho e são apresentados os métodos de registro a serem aplicados durante o trabalho, assim como os procedimentos a serem seguidos para alcançar os objetivos propostos. No quarto capítulo são apresentados resultados alcançados utilizando os procedimentos apresentados. No quinto capítulo são apresentadas as conclusões obtidas com a pesquisa e recomendações para pesquisas futuras.

2 REVISÃO BIBLIOGRÁFICA

2.1 MEDIÇÃO DE DISTÂNCIA PELO PRINCÍPIO TIME-OF-FLIGHT

Como o nome indica, o princípio do *time-of-flight* (TOF) permite, a partir do conhecimento do tempo de propagação, calcular a distância percorrida por um pulso de luz entre o sensor e os objetos. O princípio se baseia na emissão de radiação eletromagnética modulada e no registro da porção refletida pelo objeto. No momento em que é detectada a radiação refletida, o tempo decorrido entre os registros da emissão e do retorno é calculado, ou seja, o tempo necessário para que a radiação percorra o trajeto até um objeto refletor e retorne ao sensor. Conhecendo-se a velocidade da luz, pode-se então calcular a distância total percorrida pelo sinal emitido no intervalo de tempo medido. Percebe-se, porém, que para obter medidas de distância com alta acurácia e precisão, é necessária a medição do tempo com precisão e acurácia também altas. Para obter medições com acurácia de ordem milimétrica são necessárias medições de tempo na ordem do picosegundo. (LANGE, 2000).

Os sistemas que utilizam TOF para medir distâncias, normalmente utilizam modulação pulsada ou contínua da energia. A modulação pulsada é a forma mais simples para a medição da distância, pois é basicamente a medição direta do tempo de propagação do pulso emitido. Essa forma de medição consiste na emissão de pulsos com grande quantidade de energia em curtos períodos de tempo. Devido à grande quantidade de energia é possível reduzir, dessa forma, a influência da luminosidade do ambiente na medição. Ao melhorar a proporção sinal-ruído do pulso é possível se obter medições de distâncias maiores. Entretanto, para se medir o tempo com precisão é necessário considerar variações no pulso, em seu retorno, devidas a diferentes superfícies, cores, distância e variações atmosféricas, que podem alterar a intensidade do pulso, assim como seu comportamento, ou modulação. Uma grande dificuldade desta tecnologia é a geração de pulsos de alta intensidade em curtos períodos de tempo. Atualmente os únicos elementos ópticos capazes de gerar este tipo de pulso são diodos de LASER, porém sua taxa de repetição é relativamente baixa, em torno de 10 kHz. Atualmente, esta é a tecnologia mais comumente encontrada nos sistemas *laser scanner*. (LANGE, 2000).

Além da modulação pulsada, outra forma de medição do TOF é pelo cálculo da diferença de fase de uma onda contínua modulada. Essa forma tem maiores possibilidades em termos de emissores de energia, pois não há a necessidade de pulsos instantâneos. A forma de medição não se dá pela diferença de tempo medida diretamente, mas sim pela diferença de fase entre o pulso emitido e o pulso de retorno. Conhecendo-se a frequência de modulação da onda, ao se medir a diferença de fase da onda em seu retorno pode-se calcular o tempo e a distância percorridos por ela. (LANGE, 2000).

2.1.1 Medição pela diferença de fase de um sinal modulado

Para a determinação da diferença de fase entre os dois sinais, é necessário efetuar a demodulação do sinal de retorno. A determinação da diferença de fase pode ser feita realizando a correlação cruzada entre o sinal emitido e o sinal recebido (LANGE, 2000).

Definindo-se as seguintes equações sinodais $y(t)$ para a onda recebida e $x(t)$ para a equação de demodulação da onda:

$$y(t) = 1 + a \cdot \cos(2\pi f_m t - \varphi) \quad \text{e} \quad x(t) = \cos(2\pi f_m t) \quad (2.1)$$

A função de correlação obtida pela correlação cruzada é:

$$c(\tau) = y(t) \otimes x(t) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{+\frac{T}{2}} y(t) \cdot x(t + \tau) dt = \frac{a}{2} \cos(\varphi + \tau) \quad (2.2)$$

Onde:

f_m – Frequência de modulação da onda;

τ – Atraso da onda;

φ – Diferença de fase da onda;

a - Amplitude da onda modulada;

Calculando essa função para diferentes τ , ou seja, diferentes fases da onda modulada, podem ser obtidas a fase e amplitude da onda recebida. Lange (2000)

utiliza quatro valores igualmente espaçados para τ , $\tau_0 = 0^\circ$, $\tau_1 = 90^\circ$, $\tau_2 = 180^\circ$ e $\tau_3 = 270^\circ$. Com isso a função de correlação assume as seguintes formas:

$$\begin{aligned} C(\tau_0) &= c(\tau_0) + K = \frac{a}{2} \cos(\varphi) + K \\ C(\tau_1) &= c(\tau_1) + K = -\frac{a}{2} \sin(\varphi) + K \\ C(\tau_2) &= c(\tau_2) + K = -\frac{a}{2} \cos(\varphi) + K \\ C(\tau_3) &= c(\tau_3) + K = \frac{a}{2} \sin(\varphi) + K \end{aligned} \quad (2.3)$$

Onde K é adicionado devido à energia presente no ambiente, supostamente igual para todos os sinais recebidos. Com essas quatro equações, pode-se calcular a diferença de fase (φ) da onda recebida em relação à emitida e amplitude (a) do sinal do retorno pelas equações:

$$\varphi = \arctan\left(\frac{C(\tau_3) - C(\tau_1)}{C(\tau_0) - C(\tau_2)}\right) \quad (2.4)$$

$$a = \frac{\sqrt{[C(\tau_3) - C(\tau_1)]^2 + [C(\tau_0) - C(\tau_2)]^2}}{2} \quad (2.5)$$

E com a fase da onda recebida pode-se então calcular a distância:

$$d = \frac{c}{2} \cdot \frac{\varphi}{2\pi f_m} = \frac{c\varphi}{4\pi f_m} \quad (2.6)$$

Onde:

d – Distância;

c – Constante da velocidade da luz;

φ – Fase da onda recebida;

f_m – Frequência de modulação da onda;

A câmera utilizada neste trabalho fornece três imagens diferentes (figura 1). Uma imagem contendo dados da amplitude do sinal de retorno (quantidade de retorno do sinal emitido), uma imagem contendo a intensidade do sinal medido (quantidade de retorno do sinal emitido + energia presente na cena) e uma imagem

contendo valores de distância entre o sensor e os pontos iluminados pela fonte de radiação eletromagnética.




FIGURA 1 - TIPOS DE IMAGENS GERADAS PELA CÂMERA PMD CAMCUBE.

2.2 GERAÇÃO DE NUVEM DE PONTOS A PARTIR DA IMAGEM DE DISTÂNCIA

Para gerar uma nuvem de pontos a partir da imagem de distância são necessárias transformações entre referenciais, pois a câmera calcula as distâncias em um sistema coordenadas polares e para obter as coordenadas tridimensionais é necessário realizar a projeção ortogonal dos pontos no espaço. (OLIVEIRA, 2011)




FIGURA 2 - COLINERIDADE ENTRE OS PONTOS.
FONTE: OLIVEIRA (2011)

A figura 2 ilustra como é feita a projeção ortogonal dos pontos a partir da condição de colinearidade entre um ponto na imagem, o centro perspectivo da câmera e o ponto correspondente no objeto.

A primeira etapa para a transformação das coordenadas é fazer a translação da origem do sistema de coordenadas da imagem para o centro da imagem:

$$\begin{bmatrix} C' \\ L' \end{bmatrix} = \begin{bmatrix} C \\ L \end{bmatrix} - 1/2 \begin{bmatrix} n_c - 1 \\ n_l - 1 \end{bmatrix} \quad (2.7)$$

onde:

C, L – Coordenadas da imagem com origem no canto superior esquerdo;

n_c, n_l – Número total de colunas e linhas, respectivamente, da imagem;

C', L' – Coordenadas com origem no centro da imagem.

Em seguida, deve-se realizar uma reflexão para transformar o sistema levógiro da imagem em um sistema dextrógiro. Essa reflexão é efetuada no eixo L' das linhas da imagem:

$$\begin{bmatrix} x_p \\ y_p \end{bmatrix} = \begin{bmatrix} C' \\ -L' \end{bmatrix} \quad (2.8)$$

onde:

x_p, y_p – Coordenadas da imagem no sistema dextrógiro.

O passo seguinte é a correção da origem do sistema em relação às coordenadas do ponto principal.

$$\begin{bmatrix} x'_p \\ y'_p \end{bmatrix} = \begin{bmatrix} x_p \\ y_p \end{bmatrix} - \begin{bmatrix} x_0 \\ y_0 \end{bmatrix} \quad (2.9)$$

onde:

x'_p, y'_p – Coordenadas no sistema referencial fotogramétrico em pixels;

x_0, y_0 – Coordenadas do ponto principal da câmera na imagem.

Para obter as coordenadas no sistema fotogramétrico em milímetros, multiplica-se as coordenadas do sistema fotogramétrico em *pixels* pelo tamanho físico do *pixel*. No caso de sensores com tamanhos de *pixel* diferentes para x e y , o cálculo do tamanho se dá pela equação 2.10:

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} P_x & 0 \\ 0 & P_y \end{bmatrix} * \begin{bmatrix} x'_p \\ y'_p \end{bmatrix} \quad (2.10)$$

onde:

x, y – Coordenadas no sistema referencial fotogramétrico em milímetros;

P_x, P_y – Tamanho físico dos pixels em x e y, respectivamente.

O tamanho dos pixels nas direções dos eixos é calculado pela distância focal da câmera e a distância focal ao longo dos eixos. Quando o pixel é quadrado, então apenas um destes valores deve ser calculado.

$$P_x = P \cdot \frac{f}{f_x} \quad e \quad P_y = P \cdot \frac{f}{f_y} \quad (2.11)$$

onde:

f – Distância focal fornecida pelo fabricante do equipamento;

f_x, f_y – Distância focal ao longo dos eixos x e y;

P – Tamanho do pixel fornecido pelo fabricante.

Tendo-se as coordenadas da imagem no sistema fotogramétrico em metros, é possível calcular as coordenadas da projeção dos pontos no sistema objeto. A coordenada Z pode ser obtida por:

$$Z = d_r \cdot \cos \beta \quad (2.12)$$

onde:

d_r – Distância radial ao ponto;

β – Ângulo entre o eixo central e o eixo que atinge o ponto;

Z – Coordenada Z do ponto no espaço;

O ângulo β pode ser calculado por:

$$\beta = \arctan \sqrt{\frac{x^2}{f_x^2} + \frac{y^2}{f_y^2}} \quad (2.13)$$

Com Z calculado pode-se então calcular as coordenadas X e Y dos pontos utilizando as seguintes equações:

$$X = x \frac{Z}{f_x} \quad e \quad Y = y \frac{Z}{f_y} \quad (2.14)$$

Onde:

X, Y – Respectivas coordenadas X e Y do ponto no espaço;

Com isso, são obtidas as coordenadas tridimensionais dos pontos no espaço e pode-se desta forma trabalhar com nuvens de pontos, geradas a partir das imagens de distância. Assim pode-se utilizar não só dados de câmeras de distância, mas também de qualquer outro equipamento que gere como produto nuvens de pontos, como, por exemplo, *laser scanner*.

2.3 REGISTRO GEOMÉTRICO

Para realizar a reconstrução tridimensional de uma feição, ambiente ou objeto, diversos métodos de levantamento podem ser utilizados, como, por exemplo, *laser scanner* ou fotogrametria com visão estereoscópica. Porém, independentemente do método utilizado, são raras as ocasiões em que é possível realizar a reconstrução de uma só vez com uma única estação, devido a oclusões e ângulos de abertura de sensores. Por isso, diversas capturas devem ser realizadas e então unificadas. (SALVI *et al.*, 2007).

O objetivo do registro dos pontos é obter a transformação que permita a representação de diferentes capturas em um mesmo sistema de referência. Para isso existem diversos métodos propostos, alguns requerendo um alinhamento prévio para seu funcionamento e outros dispensando o alinhamento prévio. Nos métodos que não requerem o alinhamento prévio, o objetivo é obter, pelo menos, o alinhamento inicial da transformação enquanto nos métodos que requerem o alinhamento prévio, o objetivo é obter a melhor transformação possível. (SALVI *et al.*, 2007).

Salvi *et al.* (2007) separaram os métodos nos dois grupos mencionados acima, denominando-os métodos de registro grosseiro e métodos de registro fino. Os métodos de registro grosseiro normalmente utilizam a busca de correspondências, através de determinadas propriedades geométricas, entre os dois

conjuntos de pontos para então encontrar a transformação. Entre estes métodos se encontram *Point Signature* (CHUA e JARVIS, 1997), *Spin Image* (JOHNSON, 1997; JOHNSON e HERBERT, 1999), Análise da Componente Principal (CHUNG *et al.*, 1998), *RANSAC-based DARCES* (CHEN *et al.*, 1999) e *Genetic Algorithm* (BRUNNSTRÖM e STODDART, 1996). Porém, estes métodos normalmente tem a necessidade de um ajuste posterior para que o registro seja adequado.

Os métodos de registro fino partem de um alinhamento inicial para, a partir de um processo iterativo, convergir para uma solução mais adequada. Isso é feito pela minimização de uma função de distância. Entre os métodos de registro fino pode-se encontrar o *Iterative Closest Point* (BESL e MCKAY, 1992; TURK e LEVOY, 1994; GODIN *et al.*, 1994; MASUDA *et al.*, 1996; WEIK, 1997; TRUCCO *et al.*, 1999; GELFAND *et al.*, 2003), o método de Chen e Medioni (1992) que ao invés de minimizar a distância ponto-a-ponto o faz ponto-a-plano, *Normal distributions transform* (BIBER e STRAßER, 2003) e *Matching signed distance fields* (Masuda, 2001, 2002).

Alguns destes métodos são descritos a seguir.

2.3.1 Normal Distributions Transform – NDT

O NDT foi proposto por Biber e Straßer (2003) para o registro de nuvens de pontos de *laser scanner*. Neste algoritmo em particular, a nuvem de pontos de uma varredura é analisada no plano horizontal (2D). O plano é subdividido em células maiores que a densidade de varredura. Em cada célula é contado o número de ocorrências de medições e uma função densidade de probabilidade diferenciável é usada para descrever a distribuição de pontos na célula. Essa densidade de probabilidade consiste em um conjunto de distribuições normais. A obtenção das correspondências de uma segunda nuvem de pontos ao NDT é então definida pela maximização da soma que os pontos da segunda nuvem obtêm nessa função.

O NDT modela a distribuição de todos os pontos no plano bidimensional por uma coleção de distribuições normais locais. Para cada célula, que contenha pelo menos 3 pontos são calculados os parâmetros a seguir:

- Coletam-se todos os pontos contidos na célula $X_i = 1 \dots n$

- Calcula-se a média $q = \frac{1}{n} \sum_1^n xi$
- Calcula-se a matriz de covariância $\Sigma = \frac{1}{n} \sum_1^n (xi - q)(xi - q)^T$

A probabilidade p de medir uma amostra em um ponto 2D contido nessa célula é modelada pela distribuição normal $N(q, \Sigma)$

$$p(x) \sim \exp\left(-\frac{(x - q)\Sigma^T(x - q)}{2}\right) \quad (2.15)$$

A grade obtida representa a probabilidade de um ponto ser medido em um local específico do espaço;

O problema consiste em achar a transformação que leve uma segunda nuvem de pontos ao sistema da primeira. Para isto, após a construção do mapa NDT da primeira nuvem, seguem-se os seguintes passos.

- a) Definir os parâmetros iniciais (inicialmente arbitrados ou estimados por outros métodos)
- b) Para cada amostra da segunda nuvem de pontos: aplicar a transformação com os parâmetros disponíveis;
- c) Determinar a distribuição normal correspondente a cada ponto;
- d) Avaliar a qualidade da transformação (*score*) calculando um descritor de qualidade baseado na distribuição calculada para os pontos da segunda nuvem;
- e) Aperfeiçoar os parâmetros e voltar à etapa b até alcançar o objetivo.

O algoritmo NDT foi proposto originalmente para o mapeamento de interiores orientado à navegação de robô com a suposição da verticalidade das paredes. Sendo assim suficiente a utilização de um plano horizontal para descrever a cena, porém os planos das paredes nem sempre são verticais, sendo esta, portanto, uma limitação deste método.

2.3.2 Point Signature – Assinatura Pontual

Originalmente proposto por Chua e Jarvis (1997), o algoritmo da assinatura pontual (*point signature*) consiste em comparar curvas sob a superfície do objeto.

Para isto é necessário adotar um ponto de origem p , a partir do qual todas as estimativas são efetuadas. Dado o ponto p , traça-se uma esfera virtual de raio r , que tem interseção com a superfície do objeto. A interseção entre a esfera e o objeto resulta em uma curva, o contorno C . Os pontos dessa linha são representados em um novo sistema polar de coordenadas centrado em p . A orientação dos eixos é dada por um novo sistema ortonormal formado pelo vetor normal (n_1), um vetor de referencia (n_2) e o vetor obtido pelo produto vetorial entre os dois.

O vetor normal corresponde ao vetor normal de um plano que é ajustado ao conjunto de pontos do contorno, mesmo estes não sendo coplanares. Para fins de referência, o plano é então deslocado para passar pelo ponto p . Uma vez definido este plano, todos os pontos do contorno C são projetados ao plano tangente resultando na curva C' , esta sim bidimensional. O vetor n_2 é computado como o vetor unitário que vai da origem p à projeção do ponto no plano de referência, ou curva C' . Logo, todo ponto em C pode ser caracterizado por: (a) a distância ao plano de projeção, ou seja, entre o ponto e sua projeção no plano de referência e (b) um ângulo de rotação no sentido horário θ . Então, a assinatura do ponto pode ser expressa como o conjunto de distâncias em função do ângulo θ de 0° a 360° .

Para efetuar o registro de nuvens de pontos, as assinaturas de pontos de duas visadas diferentes são comparadas para determinar potenciais correspondências. O lado negativo do algoritmo é o cálculo da assinatura dos pontos. O cálculo da interseção de esferas com superfícies complexas não é trivial, especialmente quando a superfície é representada como nuvem de pontos ou triangulações. Nessa situação, uma interpolação é necessária, aumentando o tempo de processamento e diminuindo a qualidade da assinatura do ponto. Ainda, a computação do vetor de referência é muito sensível a ruídos, e erros nessa computação afeta a qualidade da assinatura consideravelmente.

2.3.3 Spin Images

Spin Image é uma representação bidimensional da distribuição de pontos tridimensionais em uma superfície região. Assim como a assinatura pontual, *Spin*

Image foi inicialmente proposto para reconhecimento de imagens. Entretanto, tem sido usado em várias aplicações de registro desde então.

Este método consiste em projetar todos os pontos sobre um plano de referência. Para isto, é adotado um ponto p da nuvem de pontos na superfície do objeto. Com base nas coordenadas deste ponto e de pontos na sua imediata vizinhança é estimado o plano normal à superfície do objeto no local. Então os pontos na proximidade do ponto p são projetados neste plano de referência, do que duas distâncias, ou coordenadas, novas são derivadas: (a) a distância α entre cada ponto para o vetor normal definido pelo plano tangente, e (b) a distância β do ponto ao plano tangente, obtendo:

$$\alpha = \sqrt{\|x - p\|^2 - (n(x - p))^2}$$

$$\beta = n(x - p)$$
(2.16)

Sendo p um dado ponto da nuvem, n é o vetor normal no ponto p e x o conjunto de pontos vizinhos usados para gerar a *spin image*. Usando estas distâncias, um novo sistema é definido, composto pelos valores de α no eixo x e β no eixo y . Este espaço bidimensional é então discretizado. Para decidir o tamanho da célula que determina a resolução da imagem, o dobro da extensão da malha de triângulos é escolhido. Cada célula contém o número de pontos pertencentes à região correspondente.

Algumas imagens do *spin images* são computadas na primeira imagem/visada e então, as melhores correspondências são buscadas na segunda imagem/visada. Quando as correspondências dos pontos são encontradas, *outliers* são removidos usando a média e o desvio-padrão do resíduo como limiar. A transformação rígida é finalmente computada com a melhor correspondência encontrada.

O principal problema desse método é que a imagem gerada pelo *spin image* é altamente dependente da resolução do método. Para solucionar este problema, Carmichael *et al.* (1999) propuseram a *face-based spin image* em que um conjunto de pontos é interpolado dentro de cada malha triangular com o objetivo de uniformizar o número de pontos em cada computação da imagem do *spin image*. Ainda, outra abordagem foi apresentada para solucionar o problema de falsos triângulos nas malhas devido a bordas e oclusões (HUBER e HEBERT, 1999). Neste

caso, o método é usado como filtro para remover os falsos triângulos antes do registro.

Portanto, utilizando as variantes do *spin image*, bons resultados podem ser encontrados para registro de nuvens de pontos, principalmente nos casos em que o objeto medido não apresente simetrias ou padrões repetidos. No entanto, essa é uma limitação presente em boa parte dos métodos de registro geométrico.

2.3.4 Análise da componente principal

Esse método baseia-se na estimativa da direção principal da nuvem de pontos e a comparação desta direção entre duas nuvens da mesma região. É assumido que se uma região aparece em duas nuvens vizinhas, então ela deve ter a mesma orientação. Logo, se a região de sobreposição de duas nuvens de pontos for grande o suficiente, ambos os eixos principais devem ser quase coincidentes após a aplicação de uma transformação de corpo rígido. Para a estimativa da direção principal da nuvem de pontos, é efetuado o cálculo das componentes principais do conjunto de coordenadas tridimensionais. Com as componentes principais das duas nuvens, procede-se à estimativa dos parâmetros da transformação. A matriz de transformação a ser encontrada é aquela que alinha os dois eixos. Esse método é muito rápido em relação aos outros que encontram correspondências pontuais ou de curvas. Entretanto, a área de sobreposição deve ser uma região muito significativa para que bons resultados sejam encontrados. Chung *et al.* (1998) propuseram um algoritmo de registro usando os vetores de direção de uma nuvem de pontos.

O método envolve o cálculo da matriz variância covariância de cada nuvem de pontos. Então, a direção U_i do eixo principal pode ser computada através da decomposição em valor singular da matriz variância covariância. A rotação é determinada pelo produto das matrizes dos autovetores da decomposição em valor singular e o vetor de translação é determinado pela distância entre os centros de massa das duas nuvens de pontos, expresso em relação a um mesmo eixo.

A análise da componente principal é um método muito rápido, porém ele pode ser usado eficientemente somente quando há um número suficiente de pontos. Além disso, esse método obtém soluções acuradas somente quando a maior parte dos pontos é comum. Resultados são menos acurados quando a região de

sobreposição constitui uma porção menor da imagem. Na prática, uma sobreposição de 50% é considerada crítica. Porém, a solução obtida pode ser usada como alinhamento inicial para um ajuste fino posterior. O principal problema da análise da componente principal é a limitação em lidar com superfícies simétricas, pois nestes casos os autovalores obtidos representando dois eixos podem ser muito similares, causando a inversão na ordem dos eixos da matriz das componentes principais e o resultado final obtido pode ser completamente diferente da solução correta. Apesar da análise da componente principal fornecer uma solução rápida, na maioria dos casos essa solução é inadequada e muito diferente da esperada.

2.3.5 RANSAC-Based DARCES

Esse método baseia-se em encontrar a melhor correspondência de três pontos entre duas nuvens de pontos para estimar a transformação necessária para efetuar o registro (CHEN *et al*, 1998).

O arranjo espacial entre três pontos (primário, secundário e auxiliar p_p, p_s e p_a) é caracterizado pelas três distâncias entre os pontos (d_{ps} , d_{pa} e d_{as}). A hipótese do método é que existe no segundo conjunto de dados (segunda nuvem de pontos) um arranjo similar. Para isto, é analisado um ponto no segundo conjunto (p_p'), supondo que o mesmo corresponde ao primário do primeiro conjunto (p). A seguir, o correspondente ponto secundário é procurado na segunda nuvem de pontos. Para isto são considerados os pontos situados a uma distância d_{ps} de p_p' . Se não houver pontos nessa posição, outro ponto primário é testado. Caso contrário, a existência do terceiro ponto p_a' é verificada. Este ponto deve estar a uma distância d_{pa} de p_p' e d_{as} de p_s' . Uma vez que os três pontos são identificados, a transformação rígida entre ambos os conjuntos pode ser calculada. Essa busca é repetida exaustivamente para cada trio entre as duas nuvens de pontos até obter um conjunto de potenciais soluções. A solução, a transformação correta, é aquela que obtiver o maior número de correspondências entre as nuvens.

Uma modificação desse método, que busca a redução do tempo de computação relacionado à busca de correspondências, foi proposta por Chen *et al*. (1999). Os resultados obtidos foram muito bons devido à robustez do método mesmo na presença de *outliers*. Entretanto, ele pode ser somente utilizado quando o

número de pontos é relativamente baixo. Teoricamente, é um bom método. Porém, a precisão depende da resolução da superfície e o tempo de execução aumenta consideravelmente com o aumento do número de pontos, portanto pode ser somente utilizado em aplicações em que tempo não é prioritário.

2.3.6 Algebraic Surface Model

Tarel et al. (1998) propuseram um método para estimar a transformação espacial entre superfícies representadas por modelos polinomiais. Primeiro, duas superfícies polinomiais implícitas são determinadas a partir de todos os valores das nuvens de pontos usando um algoritmo linear baseado em mínimos quadrados. Em geral, os algoritmos usados para obter um modelo são iterativos e demandam um grande esforço computacional para calcular a função polinomial. Porém, o algoritmo linear não requer tanto esforço de processamento e oferece melhor repetitividade quando comparado a outros métodos de ajuste polinomial.

Esse método baseia-se em obter a função de distância entre o modelo polinomial e os pontos, e procura minimizar essas distâncias. Para melhorar a acurácia deste método, pontos fictícios são adicionados à nuvem de pontos, situados a distâncias $+c$ e $-c$ da superfície.

Como esse método não precisa de correspondência de pontos ou linhas, o tempo computacional é mais rápido comparado aos demais. Porém, um vetor normal em cada ponto é necessário para estimar o modelo, o que não é tão simples de computar quando se tem somente pontos. A principal desvantagem deste método é a necessidade de que a uma grande parte das imagens deva estar contida na região de sobreposição. Segundo os autores, o método apresenta bons resultados apenas com pouca presença de oclusões. Somente com mais de 85% de sobreposição entre os pontos a transformação é estável, em situações com oclusões ocorre um erro em translação.

2.3.7 Line-Based Algorithm

Alguns autores propuseram o uso de linhas para encontrar pares correspondentes. Exemplos são o método baseado em linhas retas de Stamos e Leordeanu (2003) e o método baseado em linhas curvas de Wyngaerd e Gool (2002).

O método de Stamos e Leordeanu baseia-se na extração de segmentos retos diretamente nas nuvens de pontos ou em imagens de distância. O algoritmo é aplicado em ambientes onde regiões planas e linhas retas podem ser facilmente encontradas. O algoritmo de segmentação determina um conjunto de linhas de borda e os planos correspondentes. Primeiro, um algoritmo robusto é usado para a busca eficiente de pares de linhas baseado no comprimento da linha e área do plano. Então, a rotação e a translação entre os pares potenciais são computadas. Finalmente, aquele que maximizar o número de planos é tomado como solução.

Alguns anos depois, os mesmos autores modificaram a abordagem usada na estimativa da transformação entre as linhas retas (CHEN e STAMOS, 2005). Como a maior parte das linhas em um ambiente estruturado é contida nos três planos de um sistema coordenado, eles propuseram computar, inicialmente, as três direções principais de cada nuvem de pontos. Por isso, a matriz de rotação é computada para cada combinação e, finalmente, aquela que maximizar o número de elementos diagonais é selecionada como solução para a rotação. O restante das matrizes de rotação é mantido, pois os resultados são supervisionados por um operador. Vetores de translação são computados conectando a interseção de dois pares de segmento. O vetor mais frequente é considerado como sendo a solução. Finalmente, o registro é refinado utilizando um método baseado em *Iterative Closest Points*.

O algoritmo obtém bons resultados mesmo considerando que se trata de um método de registro grosseiro. As principais desvantagens são a dificuldade em segmentar os segmentos retos e a necessidade de um supervisor para verificar os resultados finais fornecidos pelo método. Estas desvantagens reduzem o número de aplicações para o método, porém, para o registro de edifícios o método apresenta bons resultados.

Este caso geral de correspondências baseadas em linha pode ser estendido a linhas curvas para o registro de superfícies mais complexas, como relatado por

Wyngaerd e Gool (2002). Comparado aos outros métodos que fazem a correspondência por pontos, esse método tem a vantagem das imagens serem transformadas no espaço dual antes que a busca por possíveis correspondências inicie. Essa transformação reduz o tempo computacional e aumenta a robustez. Entretanto, dependendo da forma do objeto, o número de pontos bitangentes pode ser insuficiente para garantir bons resultados.

2.3.8 Algoritmos Genéticos

Brunnström e Stoddart (1996) usaram um método baseado em algoritmos genéticos para solucionar o problema da busca de correspondências entre duas imagens de distâncias. O interesse deste método é centrado em definir um vetor que contenha os n índices de correspondências entre as nuvens de pontos ou imagens de distância.

Algoritmos genéticos requerem uma função de aptidão para medir a qualidade de cada possível solução e assim determinar a solução mais apropriada. Para determinar essa função de aptidão, quatro invariantes entre os dois pares de correspondências são usadas, uma relacionada à distância, e as outras três relacionadas à orientação angular relativa, utilizando as normais, entre os pontos.

Usando estas invariantes, a qualidade de um par de correspondências é computada analisando o erro da distância e o erro dos parâmetros das normais. A qualidade da correspondência de um ponto pode então ser computada como a soma das componentes de qualidade de cada par de correspondências formado entre este dado ponto e os outros pontos. Somando-se todas as componentes de qualidade, obtém-se uma componente de qualidade global, que indica a qualidade da correspondência entre as nuvens.

Com a definição de uma função de aptidão apropriada, as probabilidades de recombinação (*crossover*) e mutação são fixadas para caracterizar o algoritmo. A mutação não é tão importante quando buscando correspondências, pois índices próximos não necessariamente indicam proximidade espacial. Portanto, o autor define a probabilidade de mutação em 1%, com recombinação de 90%.

Finalmente, o critério de parada deve ser definido. Três diferentes abordagens são apresentadas: (a) quando uma porcentagem de boas

correspondências é alcançada; (b) a aptidão não melhorou após um certo número de iterações; (c) após um número fixo de iterações.

Quando o algoritmo de busca termina, a função de transformação pode ser computada, pois o cromossomo que maximiza a função de aptidão contém as correspondências entre os pontos. Porém, algumas correspondências nesse vetor cromossomo podem estar erradas, o que significa que essas correspondências devem ser previamente removidas para garantir uma boa transformação. Para isso, somente 30% das correspondências que maximizam a componente de qualidade global são usadas na computação da transformação. Como nas abordagens mais genéricas, os resultados obtidos são relativamente bons, mas o tempo de processamento é alto, especialmente na presença de grande quantidade de pontos, onde existem muitas correspondências em potencial. Como o algoritmo baseado em RANSAC, ele não é apropriado para situações em que o tempo é importante.

2.3.9 *Iterative Closest Point*

O método do *Iterative Closest Point* (ICP) apresentado por Besl e McKay (1992) tem como objetivo uma solução acurada através da minimização da distância das correspondências entre os pontos por um processo iterativo. Para cada ponto p_i de um conjunto de pontos P , o método busca o ponto mais próximo q_i no segundo conjunto de pontos Q , para que as distâncias entre as correspondências sejam minimizadas.

Depois de encontradas as correspondências entre os dois conjuntos de pontos, são calculadas a rotação e translação descritas por tais correspondências, seguida de uma nova seleção de correspondências, alternando estes processos até que apresente sinais de convergência, indicado pela diferença entre iterações subsequentes. Ao atingir o limiar desejado, o processo para e apresenta o resultado.

Este método apresenta bons resultados mesmo na presença de ruídos, porém apresenta dificuldade de registro de nuvens que não apresentem alta sobreposição e pode convergir erroneamente caso não seja fornecido um alinhamento inicial adequado. Este alinhamento inicial pode se obtido de algumas formas: fornecidos por sensores que tenham informação de orientação e posição no momento do levantamento; registros geométricos utilizando outros métodos; ou

manualmente pelo utilizador, utilizando características distinguíveis visualmente nas nuvens.

Todos os métodos mostrados anteriormente apresentam soluções para o problema de registro de nuvens de pontos. Para este trabalho, porém, será utilizado o *Iterative Closest Point* por ser um método bastante difundido para a solução deste problema e devido à sua disponibilidade na biblioteca *Point Cloud Library*, que será utilizada para o desenvolvimento dos algoritmos. Além disso, a implementação computacional dos métodos apresentados não se trata de uma tarefa trivial, pois em suas descrições são apenas indicadas as etapas metodológicas realizadas e não seus passos computacionais detalhadamente.

3 MATERIAIS E MÉTODOS

Para alcançar os objetivos desejados, este trabalho realiza os seguintes procedimentos. De uma cena de interesse são coletadas, utilizando a câmera PMD CamCube3.0, diversas imagens de distância com alta taxa de sobreposição, obtidas com pequenas variações angulares ou deslocamentos posicionais. Destas imagens, a partir da formulação indicada na seção 2.2, são geradas nuvens de pontos tridimensionais da cena. Através de um algoritmo que utiliza o método do *Iterative Closest Points*, as nuvens são registradas, duas a duas, para que fiquem referenciadas a um mesmo sistema de coordenadas.

Para a verificação da precisão, uma nuvem coletada com *laser scanner* será considerada como isenta de erros, sabendo-se que a sua qualidade é superior à da câmera, e será comparada ao resultado do registro. Para isso o resultado do registro das imagens da câmera será registrado à nuvem do *laser scanner* por um processo de duas etapas, um alinhamento prévio utilizando um algoritmo baseado em RANSAC e o alinhamento preciso utilizando o *Iterative Closest Point*. Em uma situação ótima, na ausência de distorções nas nuvens e com um registro isento de erros, ambas as nuvens devem ser coincidentes. Na prática, porém, isto não ocorre e discrepâncias e distorções relacionadas ao processo de registro podem assim ser identificadas e analisadas. Os procedimentos adotados são apresentados de forma mais detalhada posteriormente.

3.1 MATERIAIS UTILIZADOS

Para este trabalho, serão utilizadas a câmera PMD CamCube3.0 e a biblioteca *Point Cloud Library*.

A câmera CamCube3.0 é uma câmera que utiliza o princípio TOF pela diferença de fase para a determinação da distância aos objetos imageados. Fornece um software próprio para aquisição das imagens, além de *plugins* para comunicação com softwares desenvolvidos em linguagem C++ e MATLAB. As especificações técnicas da câmera são apresentadas no quadro 1.

QUADRO 1 – ESPECIFICAÇÕES TÉCNICAS DA CÂMARA PMD CAMCUBE3.0

PARÂMETRO	VALOR
Alcance de Medição	0,3 a 7 m
Repetibilidade da medição (Precisão)	< 3 mm
Frequência de aquisição de imagens	40 fps @ 200x200 pixels 60 fps @ 176x144 pixels 80 fps @ 160x120 pixels
Campo de Visão	40° x 40°
Comprimento de onda	870 nm

FONTE: PMD TECHNOLOGIES (2010)

A câmera CamCube3.0 utiliza uma fonte de iluminação no infravermelho próximo e possui uma resolução variável de até 200x200 *pixels*. Alcançando uma precisão de 3mm ao imagear um objeto com refletividade de 75%, a uma distância de 4m. Possui um dispositivo de supressão da iluminação do ambiente o que permite seu uso em ambientes externos, assim como internos.

A *Point Cloud Library* é uma biblioteca gratuita, escrita em linguagem C++, que integra diversos algoritmos para processamento de nuvens de pontos, auxiliando na realização de tarefas como filtragem de pontos, segmentação, extração de *keypoints* e feições, e ainda visualização de nuvens de pontos, além de alguns métodos de registro geométrico, entre eles o *Iterative Closest Point* e *Sample Consensus Initial Alignment*, utilizados neste trabalho.

Nas etapas posteriores do trabalho, foi utilizado também o software CloudCompare, um software gratuito que oferece algumas ferramentas para visualização e tratamento de nuvens de pontos. Sua principal utilização neste trabalho foi para a remoção e seleção de certas regiões das nuvens de pontos trabalhadas que foram feitas para a análise dos resultados.

3.2 ITERATIVE CLOSEST POINT - ICP

Dentre os métodos apresentados na seção 2.3, o *Iterative Closest Point* é um dos mais utilizados e é mencionado como um dos métodos mais populares por diversos autores (MITRA *et al.*, 2004; MAY *et al.*, 2009, SEHGAL *et al.*, 2010) para o registro de nuvens de pontos, devido a seu desempenho e simplicidade. O método descrito por Besl e McKay (1992) é apresentado a seguir.

O método encontra as correspondências entre dois conjuntos de pontos, onde para cada ponto p_i é encontrado um ponto x_i correspondente, e realiza o registro entre os dois conjuntos determinando as correspondências que minimizam o erro médio quadrático. A equação do erro médio a ser minimizada é uma transformação de similaridade:

$$f = \frac{1}{N_P} \sum_{i=1}^{N_P} \|\vec{x}_i - R(\vec{q}_R)\vec{p}_i - \vec{q}_T\|^2 \quad (3.1)$$

Onde \vec{q}_R são os parâmetros referentes às rotações e \vec{q}_T os parâmetros referentes às translações. Para computar os parâmetros de rotação pode-se utilizar quaternions ou decomposição em valor singular. Besl e McKay apresentam a solução pelo método de quaternions como solução preferida para duas ou três dimensões, pois não é influenciado por reflexões. Para mais de três dimensões, porém, citam que o método da decomposição em valor singular seria a escolha devido à facilidade para generalizar para n-dimensões.

Uma etapa preliminar para a determinação da rotação entre os dois conjuntos de pontos é o cálculo de sua covariância cruzada. Para isso é realizado a redução dos dois conjuntos de pontos em relação aos seus respectivos centros:

$$\vec{\mu}_P = \frac{1}{N_P} \sum_{i=1}^{N_P} \vec{p}_i \text{ e } \vec{\mu}_X = \frac{1}{N_X} \sum_{i=1}^{N_X} \vec{x}_i \quad (3.2)$$

A covariância cruzada é então obtida por:

$$\Sigma_{PX} = \frac{1}{N_P} \sum_{i=1}^{N_P} [(\vec{p}_i - \vec{\mu}_P)(\vec{x}_i - \vec{\mu}_X)^t] = \frac{1}{N_P} \sum_{i=1}^{N_P} [\vec{p}_i \vec{x}_i^t] - \vec{\mu}_P \vec{\mu}_X^t \quad (3.3)$$

Os componentes cíclicos da matriz antissimétrica $A_{ij} = (\Sigma_{PX} - \Sigma_{PX}^T)_{ij}$ são usados para formar o vetor $\Delta = [A_{23} \ A_{31} \ A_{12}]$. Esse vetor é usado para construir a matriz simétrica $Q(\Sigma_{PX})$:

$$Q(\Sigma_{PX}) = \begin{bmatrix} tr(\Sigma_{PX}) & \Delta^T \\ \Delta & \Sigma_{PX} + \Sigma_{PX}^T - tr(\Sigma_{PX})I_3 \end{bmatrix} \quad (3.4)$$

Onde I_3 é a matriz identidade 3x3. Pelo método de quaternions, ao computar os autovalores e autovetores, o autovetor correspondente ao maior autovalor de $Q(\Sigma_{PX})$ é o quaternion $\vec{q}_R = [q_0 \ q_1 \ q_2 \ q_3]^t$ que corresponde à rotação ótima entre os dois conjuntos de pontos. A matriz de rotação correspondente a um dado quaternion pode ser obtida por:

$$R = \begin{bmatrix} q_0^2 + q_1^2 - q_2^2 - q_3^2 & 2(q_1q_2 - q_0q_3) & 2(q_1q_3 + q_0q_2) \\ 2(q_1q_2 + q_0q_3) & q_0^2 + q_2^2 - q_1^2 - q_3^2 & 2(q_2q_3 - q_0q_1) \\ 2(q_1q_3 - q_0q_2) & 2(q_2q_3 + q_0q_1) & q_0^2 + q_3^2 - q_1^2 - q_2^2 \end{bmatrix} \quad (3.5)$$

A translação ótima é então dada por:

$$\vec{q}_T = \vec{\mu}_X - R(\vec{q}_R)\vec{\mu}_P \quad (3.6)$$

Alternativamente, para a obtenção da rotação ótima pode ser utilizada a decomposição em valor singular. A decomposição em valor singular é a solução utilizada na implementação do ICP encontrada na *Point Cloud Library* (PCL). A decomposição em valor singular é uma fatorização da seguinte forma:

$$A = U\Sigma V^* \quad (3.7)$$

Nessa equação a matriz A é a matriz de covariância cruzada, a matriz V é composta pelos autovetores de $A^T A$. A matriz U é composta pelos autovetores de AA^T . A matriz Σ é uma matriz diagonal composta pelas raízes dos autovalores de $A^T A$ ou de AA^T , são os mesmos para as duas matrizes. Os sinais dos autovetores podem variar dependendo do critério escolhido para atribuição dos sinais. Para evitar que isso ocorra, pode-se utilizar o primeiro conjunto de autovetores para o cálculo do segundo. O cálculo da matriz U é dado por:

$$U = A.V.\Sigma^{-1} \quad (3.8)$$

Com as matrizes V e U , é possível calcular a rotação pela seguinte equação:

$$R = V \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & d \end{bmatrix} U^T \quad (3.9)$$

Nessa equação, d assume o valor +1 ou -1, de acordo com o sinal do determinante de VU^T .

O algoritmo aplica a transformação, rotação e translação, a um dos conjuntos de pontos e verifica os critérios de parada e encerra a iteração. Para cada iteração é novamente realizada a busca por correspondências e uma nova transformação é calculada, isso é feito até o momento em que os critérios de parada são atingidos. Os critérios de parada podem ser: um critério de convergência, quando as transformações calculadas tiverem pouca diferença entre si, ou um número máximo de iterações seja atingido.

Desde a sua concepção original, diversos métodos variantes do ICP foram apresentados (TRUCCO *et al.*, 1999; GREENSPAN E GODIN, 2001; JOST E HUGLI, 2002; SHARP *et al.*, 2002; CHETVERIKOV *et al.*, 2002; ZINSSER *et al.*, 2003). Segundo Rusinkiewicz e Levoy (2001), estas variantes podem ser classificadas dependendo da etapa em que ela altera método original:

- a) Na seleção de um subconjunto de pontos de uma ou ambas as nuvens;
- b) Na correspondência dos pontos entre as nuvens;
- c) Na ponderação apropriada dos pares correspondentes;
- d) Na rejeição de pares considerando cada par individualmente ou considerando o conjunto total de pares;
- e) Na determinação do parâmetro para avaliação do erro;
- f) Na forma de minimização do erro.

Segundo Segal *et al.* (2009) dois principais problemas do ICP são a suposição da sobreposição total das duas nuvens de pontos e a suposição da posição dos pontos correspondentes ser exatamente a mesma nas duas nuvens de pontos. A suposição da sobreposição total falha ao se medir um objeto ou uma superfície a partir de posições diferentes, pois a área de recobrimento do sensor não será a mesma. E, ao contrário de uma superfície teórica em que a posição dos pontos é exata, uma superfície medida possui variações nas posições dos pontos, assim a suposição dos pontos estarem situados exatamente na mesma posição também falha. Assumindo a utilização de nuvens com um alinhamento prévio, para solucionar o problema de não sobreposição total pode-se determinar um limiar máximo de distância para as correspondências, pois se assume, devido ao alinhamento prévio, que os pontos que possuem correspondências estão a uma dada distância (limiar) do seu ponto correspondente. Para o problema da posição não exata dos pontos pode-se utilizar uma solução de ponto-a-plano ao invés de

ponto-a-ponto, porém isso não é crucial, pois, como a influência da posição não exata dos pontos é da ordem da distância média entre os pontos das nuvens e é uma diferença aleatória, essa influência resultará apenas em um pequeno deslocamento na nuvem transformada.

3.3 ALINHAMENTO PRÉVIO: *SAMPLE CONSENSUS INITIAL ALIGNMENT*

O *Sample Consensus Initial Alignment* (SAC-IA) é um método de alinhamento inicial baseado em RANSAC que busca manter as relações geométricas das correspondências sem a necessidade de testar todas as combinações possíveis de um dado conjunto de possíveis correspondências (RUSU *et al.*, 2009). Para isso, é feita a amostragem de um grande número de candidatos e estes são rapidamente ordenados da seguinte forma: uma amostra de S pontos é selecionada de uma nuvem de pontos P certificando-se que a distância entre eles é maior que uma distância mínima definida pelo usuário. Essa distância mínima é utilizada para garantir que pontos os pontos, selecionados aleatoriamente, não pertençam a uma só região da nuvem. Para cada um dos pontos amostrados, encontra-se uma lista de pontos numa segunda nuvem Q cujos histogramas são semelhantes ao histograma do ponto amostrado considerado. Desta lista, um ponto é escolhido aleatoriamente como sendo a correspondência do ponto amostrado. Com os pontos amostrados e suas correspondências, pode-se calcular a transformação rígida definida por eles e calcular uma métrica de erro para indicar a qualidade da transformação. Estes passos são repetidos e a transformação que resultou na melhor métrica de erro é armazenada e utilizada para realizar o alinhamento. Para computar o histograma são utilizados os algoritmos do *Point Feature Histogram* (PFH) e *Fast Point Feature Histogram* (FPFH).

3.3.1 *Point Feature Histogram* e *Fast Point Feature Histogram*

Conforme descrito em RUSU (2008) e RUSU *et al.* (2009), os histogramas das características dos pontos são características locais informativas independentes à pose, que representam as propriedades do modelo da superfície subjacente em

um dado ponto p . Sua computação é baseada na combinação de certas relações entre os k vizinhos mais próximos de p , como coordenadas 3D dos pontos e normais da superfície estimadas, mas são extensíveis para o uso de outras propriedades como curvatura, invariantes de momento de segunda ordem, entre outros.

Basicamente, a computação de um *Point Feature Histogram* (PFH) em um ponto p depende da presença das coordenadas 3D e normais estimadas da superfície, e é feito da seguinte forma: para cada ponto p , todos os seus vizinhos inclusos em uma esfera com um dado raio r são selecionados. Em seguida, estimam-se as normais n_i e n_j cada par de pontos p_i e p_j ($i \neq j$) (na vizinhança- k de p) e define-se um sistema Darboux uvn ($u = n_i$, $v = (p_i - p_j) \times u$, $w = u \times v$) e computa-se variações angulares entre n_i e n_j de acordo com as equações:

$$\begin{aligned}\alpha &= v \cdot n_j \\ \phi &= u \cdot \frac{(p_j - p_i)}{\|p_j - p_i\|^2} \\ \theta &= \arctan(w \cdot n_j, u \cdot n_j)\end{aligned}\tag{3.10}$$

Para cada feição $f_x = (\alpha, \phi, \theta)$ definem-se os limites teóricos máximo e mínimo ($f_{x\min}$, $f_{x\max}$) e divide-se essa variação em d subdivisões. Para criar a representação final do PFH para um ponto p_i , o conjunto de tuplas $\langle \alpha, \phi, \theta \rangle$ é armazenado em um histograma. O processo de armazenamento divide a amplitude de cada valor característico do ponto (α, ϕ, θ) em d subdivisões, e conta-se o número de ocorrências em cada subdivisão, definindo um total de d^3 divisões. A subdivisão em que as feições se encontram é determinada pela equação:

$$idx = \sum_{x=1}^{x \leq 3} op_d\left(\frac{f_x}{f_{x\max} - f_{x\min}}\right) \cdot d^{x-1}\tag{3.11}$$

Onde op_d é uma operação que resulta em valores inteiros de 0 a $d-1$. No caso de $d=2$, op_d resulta em valores 0 ou 1, 0 quando for menor que 0,5 e 1 caso contrário.




FIGURA 3 - PONTOS VIZINHOS UTILIZADOS PARA O CALCULO DO PFH.
FONTE: RUSU (2008)

A figura 3 mostra um diagrama da região de influencia da computação do PFH para um dado ponto (p_q). p_q está marcado em vermelho no centro da esfera de raio r , e todos seus k vizinhos, com distancias menores que o raio r , são interligados em uma malha.

Uma otimização para o FPH é feita através do armazenamento da vizinhança comum entre os pontos juntamente com o seu ordenamento, reduzindo a quantidade de cálculos ao utilizar valores armazenados. Com isso, um outro algoritmo, *Fast Point Feature Histogram* (FPFH), foi desenvolvido aproveitando essa otimização da seguinte maneira: para cada ponto p são computadas somente as relações entre ele e seus vizinhos (SPFH) e, para cada ponto, os k -vizinhos são redeterminados e os SPFH são utilizados para ponderar o histograma de p (FPFH).

$$FPFH(p) = SPFH(p) + \frac{1}{k} \cdot \sum_{1}^k w_k \cdot SPFH(p_k) \quad (3.12)$$

O diagrama da região de influencia ilustrando a computação do FPFH é apresentado na figura 4. Para cada ponto (p_q) do conjunto de dados, são calculados os valores do SPFH com relação a seus vizinhos (p_k). Então, os valores do SPFH dos vizinhos de cada um dos pontos (p_q) são ponderados de acordo com os valores do SPFH de seus vizinhos (p_k) calculando assim o FPFH de p_q .




FIGURA 4 - PONTOS VIZINHOS UTILIZADOS PARA O CALCULO DO FPFH.
FONTE: RUSU (2008)

Para selecionar os pontos significativos, os pontos cujos PFH's/FPFH's são mais diferentes dos históricos médios da nuvem ($PFH > \mu_{PFH} \pm \sigma_{PFH}$) são dados como sendo incomuns e, portanto com maior probabilidade de serem únicos. Considerando-se estes pontos reduz-se a possibilidade de correspondências ambíguas devido a abundância de pontos com PFH's semelhantes.

3.4 ALINHAMENTO PRÉVIO: *Alignment Prerejective*

O método descrito por Buch *et al.* (2013) busca determinar a transformação $\hat{T} \in SE(3)$ entre um modelo e uma cena de referência, que minimize a soma das distâncias quadráticas entre cada um dos pontos p no modelo do objeto P e os seus respectivos pontos correspondentes q no modelo da cena Q :

$$\hat{T} = \underset{T}{\operatorname{argmin}} \varepsilon(T) = \underset{T}{\operatorname{argmin}} \sum_{p \in P} (Tp - q)^2 \quad (3.13)$$

O problema indicado acima é normalmente abordado através de um método robusto e tolerante a *outliers*, como RANSAC. Uma forma comum de tratar essa questão baseia-se na correspondência de feições. Assim, as seguintes etapas são executadas iterativamente: encontra-se $n \geq 3$ pontos objeto (p) aleatórios em P e seus correspondentes em Q por uma correspondência de vizinho mais próximo usando descritores de características invariantes de $SE(3)$. Em seguida estima-se uma transformação hipotética \hat{T} usando as n correspondências amostradas e aplica-se esta transformação ao modelo P . Encontram-se, então, pontos *inliers* através de

uma busca espacial por vizinho mais próximo entre o objeto transformado e a cena Q , aplicando um limiar euclidiano. Se esse número de *inliers* for baixo, o algoritmo busca novos pontos para encontrar um novo \hat{T} (etapa 1). Caso contrário, estima-se uma nova transformação hipotética \hat{T} usando as correspondências dos pontos *inliers*. Finalmente, calcula-se $\varepsilon(\hat{T})$ usando os *inliers* e se o valor calculado for o menor valor, define-se \hat{T} atual como transformação resultante.

Aplica-se uma modificação ao processo RANSAC descrito acima através de uma restrição geométrica após o primeiro passo de cada iteração. Para isso, explora-se o fato de que as distâncias são preservadas nas transformações. Mais especificamente, é realizada uma checagem da proporção entre os comprimentos dos lados dos polígonos virtuais formados pelos n pontos amostrados em ambos os modelos. Sendo $p_i, q_i, i \in \{1, \dots, n\}$ os pontos amostrados pelas correspondências de feições. Os comprimentos dos lados dos polígonos do objeto são dados por $d_{p,i} = \|p_{i+1 \bmod n} - p_i\|$ e da mesma maneira para os lados dos polígonos da cena. Então é calculada um vetor de dissimilaridade δ pelas proporções entre os n comprimentos dos lados dos polígonos:

$$\delta = \left[\frac{|d_{p,1} - d_{q,1}|}{\max(d_{p,1}, d_{q,1})} \quad \dots \quad \frac{|d_{p,n} - d_{q,n}|}{\max(d_{p,n}, d_{q,n})} \right] \quad (3.14)$$

No caso de uma correspondência exata entre dois polígonos, δ é igual a zero. Na pratica, espera-se que a maior discrepância se encontre abaixo de um limiar t_{poly} :

$$\|\delta\|_{\infty} \leq t_{poly} \quad (3.15)$$

Logo, a modificação é a inserção do seguinte passo entre as etapas 1 e 2: Calcular o vetor de dissimilaridade δ entre as distancias dos lados dos polígonos amostrados. E se $\|\delta\|_{\infty} > t_{poly}$, volta-se à etapa inicial.

Essa verificação é muito mais simples do que a verificação completa através do processo inteiro. Com base na suposição de que esta etapa não elimina transformações hipotéticas que alinhem os modelos corretamente, pode-se esperar a mesma probabilidade de sucesso com um tempo muito mais curto. No caso de sensores com maiores quantidades de erro ou distorções, o limiar t_{poly} deve ser mais brando para permitir tais inaccurácias.

3.5 PROCEDIMENTOS

Os passos realizados para a execução do trabalho são ordenados conforme o fluxograma apresentado na figura 5.

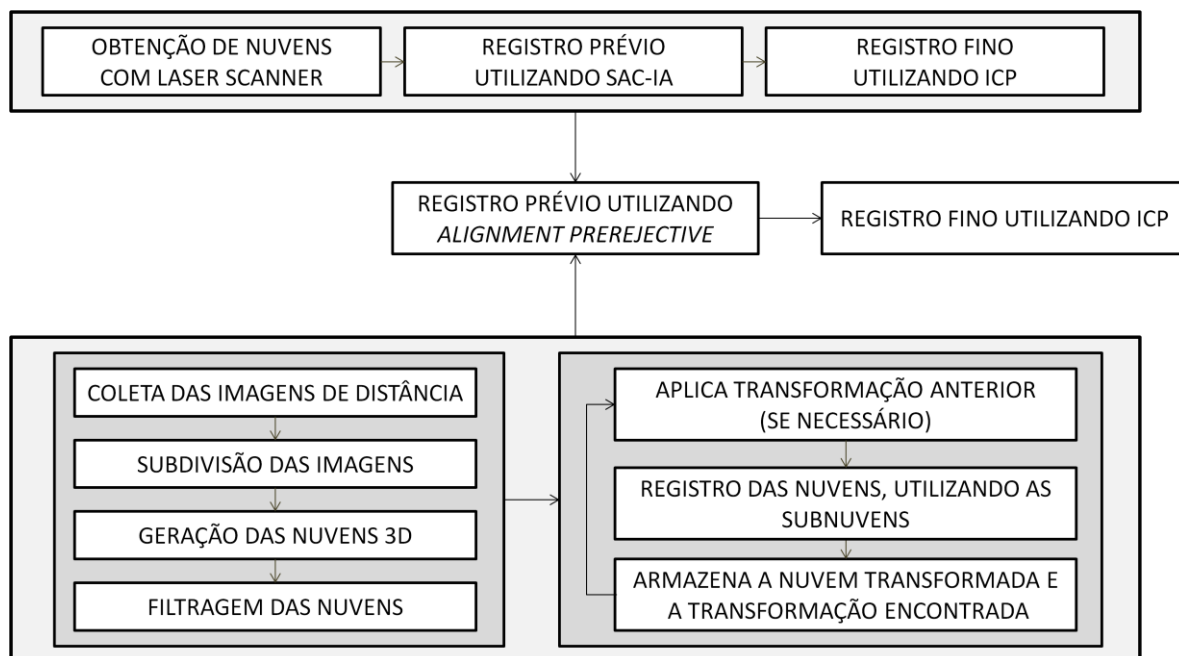


FIGURA 5 – FLUXOGRAMA DAS ETAPAS REALIZADAS
FONTE: O AUTOR

Para o registro das nuvens da câmera, a primeira etapa se trata da captura das imagens de distância. Esta é uma etapa relativamente simples, pois se assemelha à tomada de uma fotografia convencional. Porém, deve-se estar atento à disposição dos objetos no ambiente imageado, para que as imagens obtidas gerem nuvens que contenham feições que possibilitem o registro.

Para este trabalho, as imagens foram tomadas em salas de dimensões similares, de aproximadamente 4m x 7m e as imagens foram capturadas a distâncias entre 2m e 3m das paredes. A estas distâncias, uma imagem tomada com a câmera utilizada recobre uma área de aproximadamente 2m x 2m no objeto imageado.

Para a obtenção das nuvens, variações angulares e deslocamentos foram feitos no sensor entre as tomadas. Considerando a abertura angular do sensor e a área recoberta no objeto imageado, podem-se definir valores para estas variações e deslocamentos. No caso angular, para garantir um mínimo de 50% de recobrimento, sem que haja a necessidade de um deslocamento no sentido contrário, a variação

deve ser de no máximo 20° entre as tomadas. Para os deslocamentos, estes devem ser inferiores a 1m, para manter um mínimo de 50% de recobrimento. Porém, considerando possível a presença de objetos situados mais próximo ao sensor, nestes casos o deslocamento entre as tomadas deve ser menor, de acordo com a distância e tamanho destes objetos.

Como apresentado na literatura e como pode ser observado pelas equações apresentadas em 3.2, o ICP, em sua conceituação básica, utiliza todos os pontos da nuvem de pontos para a realização do registro das nuvens. O algoritmo do ICP implementado na PCL, a princípio, também utiliza todos os pontos das nuvens. Sendo assim indicado o fornecimento de um alinhamento prévio para que, com o parâmetro de distância máxima do algoritmo, utilizem-se apenas os pontos em comum das duas nuvens.

Para o caso das câmeras de distância, neste trabalho, em que nuvens com grande quantidade de pontos em comum são coletadas, realizar um alinhamento prévio para cada par de imagens é uma etapa indesejada. Para evitar a necessidade dessa etapa, além da alta taxa de sobreposição, foi feita a subdivisão das nuvens para realizar o registro utilizando nuvens com recobrimento de apenas metade da região imageada, como é apresentado na seção 3.5. Com isso, podem-se obter nuvens com todos, ou quase todos, os pontos da nuvem a ser registrada contidos na nuvem anterior e pode-se, portanto, utilizar o ICP sem uma orientação prévia. O registro de um par de nuvens feito desta forma é mostrado na figura 6.




FIGURA 6 - REGISTRO DE DUAS NUVENS. A NUVEM EM AZUL É A NUVEM A SER REGISTRADA, A NUVEM EM VERMELHO É A NUVEM COM APENAS METADE DO QUADRO PARA O PRIMEIRO ALINHAMENTO E A NUVEM EM VERDE, A NUVEM DE DESTINO.

FONTE: O AUTOR

Depois de realizar o alinhamento, a transformação encontrada e a nuvem resultante são salvas. Para a nuvem do quadro seguinte, a transformação do quadro anterior é aplicada previamente ao registro, desta forma as coordenadas estarão no mesmo sistema de coordenadas que a primeira nuvem. Isso é realizado para cada um dos quadros capturados com a câmera, referenciando as nuvens resultantes ao mesmo sistema da primeira nuvem.

Antes da aplicação do ICP, é realizada a filtragem dos dados da nuvem de pontos através de um processo de remoção de *outliers* descrito em Rusu *et al.* (2009). Este filtro é disponibilizado também na PCL. Com a filtragem, pontos isolados são removidos, removendo assim maior parte do ruído presente na nuvem de pontos, principalmente os *pixels* flutuantes, aqueles que ocorrem em regiões de borda de objetos situados em diferentes profundidades em relação ao sensor, em que parte do sinal é refletida pelo objeto mais próximo e parte do sinal refletido por outro objeto mais ao fundo.

O filtro baseia-se na análise estatística da vizinhança de cada ponto p contido em uma nuvem P . Para cada ponto p , a distância média \bar{d} para os seus k vizinhos mais próximos é calculada. Então é calculada a média (μ) das distâncias médias \bar{d} e é computado o desvio-padrão (σ) para a nuvem P . A nuvem de pontos filtrada (P^*) é obtida pela seguinte equação:

$$P^* = \{p \in P | (\mu - \alpha \cdot \sigma) \leq \bar{d} \leq (\mu + \alpha \cdot \sigma)\} \quad (3.16)$$

Onde α é um fator de tolerância para a filtragem.




FIGURA 7 - ETAPA DE FILTRAGEM PARA A REMOÇÃO DE RUÍDOS.
FONTE: O AUTOR

Para a execução do ICP, o algoritmo implementado aplica o ICP presente na PCL reduzindo iterativamente o parâmetro de tolerância de distância máxima. Este é iniciado com um valor relativamente alto, para que, inicialmente, todos os pontos sejam considerados, pois não há orientação prévia, e é reduzido progressivamente a valores de ordem centimétrica. O alinhamento final é, desta forma, realizado utilizando somente os pontos com correspondentes próximos nas duas nuvens. Isto reduz a possibilidade de alinhamento incorreto, principalmente no caso em que se têm poucas feições e abundância de áreas planas uniformes, como paredes, por exemplo, onde a minimização do erro se dá de forma a centralizar uma nuvem com a outra, pois a contribuição para a redução do erro seria maior ao realizar a sobreposição exata dos planos das paredes.

Para a avaliação da qualidade final do registro da câmera, será utilizada uma nuvem gerada a partir do registro de nuvens obtidas com *laser scanner* terrestre. Este registro das nuvens obtidas com *laser scanner* é feito com a finalidade de se gerar uma nuvem final para comparação com bom recobrimento de toda a área de estudo, sem vazios ou oclusões. Para o registro destas nuvens, deve ser fornecido o alinhamento prévio, feito utilizando o método do SAC-IA, e em seguida o alinhamento fino utilizando o método do ICP. Com isso se obtém uma nuvem resultante com bom recobrimento a ser utilizada para a avaliação da qualidade dos resultados.

Um processo similar é repetido para o alinhamento da nuvem resultante das câmeras de distância e da nuvem de referência do *laser scanner*. Porém, o método utilizado para o alinhamento inicial é o *Alignment Prerejective*, pois, ao contrário das nuvens do *laser scanner*, que possuem uma grande região em comum por serem escaneamentos da sala toda, a nuvem gerada com a câmera não apresenta o mesmo recobrimento, além de diferenças nas qualidades de medição dos sensores. Devido a não correspondência de todos os pontos e diferenças posicionais devido à diferença de qualidade dos sensores, nem todas os pontos podem ser considerados boas correspondências. Este método, por somente utilizar somente uma parte das correspondências para determinação da transformação, é portanto mais apropriado para o alinhamento destas nuvens.

3.5.1 Pré-análise por regiões

A solução do registro das nuvens de pontos do método ICP é muito eficiente quando as duas nuvens de pontos cobrem exatamente a mesma região, mas encontra dificuldades conforme a área comum diminui sem a realização de um alinhamento prévio. No caso do registro de nuvens de pontos obtidas com a câmara de distância, é desejado que cada uma delas cubra uma parte do objeto formando uma sequência de imagens a serem transformadas em nuvens de pontos e registradas, consequentemente, a área de sobreposição entre as imagens é menor que o quadro da imagem.

No caso das nuvens de pontos geradas pela câmara de distância, a extensão das coordenadas é a mesma para cada nuvem, ou seja, os pontos estão situados sempre na mesma região do espaço, referenciados a um mesmo sistema de referência arbitrário, pois o cálculo das coordenadas é feito independente para cada imagem. Essa orientação em comum dos pontos é justamente o que possibilita a solução apresentada para fazer o registro das nuvens.

Sabendo-se que a sobreposição das nuvens não é completa, para a realização do registro é desejável saber a área de sobreposição entre as nuvens. Porém, descobrir a área em comum entre duas nuvens não é uma tarefa simples de ser realizada. Para evitar isso, as imagens coletadas devem ter uma sobreposição de, pelo menos, 50%. Assim, como a metade de uma das nuvens é inicialmente comparada com a nuvem anterior e como a sobreposição é maior do que a metade de uma das nuvens e as duas nuvens se situam próximas uma da outra por estarem referenciadas ao mesmo sistema arbitrário, o ICP tem uma alta probabilidade de convergir, sem a necessidade do pré-alinhamento das nuvens.

Para simplificar a execução deste método, as metades das nuvens são obtidas diretamente a partir da imagem de distância gerada pela câmara, e a partir destas meias imagens são geradas as nuvens contendo apenas metade da área imageada. A partir de uma imagem de distância quatro metades podem ser geradas: esquerda, direita, superior e inferior. Utiliza-se, então, o ICP com as nuvens obtidas a partir de cada metade, e aquela que apresentar o menor erro de registro é aquela que tem a maior probabilidade de ser a metade inteiramente contida na nuvem anterior. Fazendo isso, elimina-se a necessidade de um caminhar definido

numa única direção, pois a metade anterior pode estar em qualquer porção da imagem.




FIGURA 8 - DEMONSTRAÇÃO DAS METADES DA NUVEM GERADAS.
FONTE: O AUTOR

As incertezas na obtenção de resultados apresentadas na descrição desse método são devidas à variação nos resultados obtidos de acordo com as feições presentes no ambiente. No caso de uma região com muitos detalhes característicos, como diferenças em relevo ou texturas distinguíveis, a solução correta é esperada, enquanto em uma região sem detalhes para o registro, a solução correta não é garantida, pois o ICP pode convergir a um mínimo local incorreto.

3.6 VERIFICAÇÃO DA PRECISÃO

A etapa final do projeto consiste na verificação da qualidade da nuvem registrada contendo todas as nuvens de pontos. Para isto, um modelo de referência da área de estudo é obtido com o uso de um *laser scanner* terrestre. A acurácia do modelo de referência será maior que a da câmara, podendo, assim, ser utilizado para avaliar a qualidade do produto resultante.

Para a análise da qualidade, duas amostras correspondentes de pontos são coletadas nos dois modelos. Essa análise é efetuada em função da diferença entre as duas amostras. Sendo (x, y, z) as coordenadas de um ponto no modelo produzido

pelo registro de pontos e (x_0, y_0, z_0) as coordenadas do ponto mais próximo no modelo de referência, o vetor de diferenças é dado pela equação (3.17).

$$\Delta_{xyz} = (x - x_0, y - y_0, z - z_0) \quad (3.17)$$

Das coordenadas ainda pode-se extrair a distância entre os pontos das duas amostras:

$$D = \sqrt{(x - x_0)^2 + (y - y_0)^2 + (z - z_0)^2} \quad (3.18)$$

Para cada eixo coordenado, pode-se calcular a média das diferenças e a sua variância ou desvio-padrão. Com isso tem-se um indicador de dispersão para cada eixo. Porém, isso é mais interessante para detectar a orientação das diferenças. Uma verificação mais geral da qualidade pode ser realizada utilizando as três componentes das coordenadas.

Outra forma de verificar a qualidade do resultado obtido pelo processo é o cálculo da distância dos pontos de um dado conjunto de pontos para o plano determinado pelos pontos da nuvem de referência para a região correspondente. Apesar de não ser possível aplicar esta forma de verificação para toda a nuvem por ela não se consistir somente de regiões planas, pode-se aplicá-la a diversas porções planas avaliando, assim, diversas regiões de interesse. Esta forma de determinação das diferenças permite a análise mais acurada dos resultados, pois, como o plano é uma superfície contínua, diferenças devido à não sobreposição exata dos pontos nas duas nuvens não afeta a análise dos resultados.

Para calcular o plano ajustado à dada região, é feito o cálculo dos autovalores e autovetores da matriz $M' * M$, onde M é a matriz aumentada da nuvem de pontos desta região. O autovetor relativo ao menor autovalor da nuvem de pontos corresponde à equação do plano deste conjunto de pontos. Para o cálculo da distância para este plano, as coordenadas dos pontos da nuvem da câmera são então substituídas na equação encontrada.

As regiões de interesse são regiões com propriedades distintas para a análise da qualidade esperada em diferentes situações. Essas regiões, portanto, incluem regiões onde o resultado foi adequado, para avaliar a qualidade esperada em casos favoráveis, assim como regiões propícias ou que apresentem erros, como áreas de materiais reflexivos ou próximas a cantos, afetadas pelo efeito de espalhamento, avaliando a qualidade também para estes casos.

4 RESULTADOS

A seguir são apresentados os resultados obtidos com a aplicação da metodologia descrita no capítulo anterior para o registro das nuvens e para avaliação da qualidade do resultado.

4.1 REGISTRO DAS NUVENS DA CÂMERA DE DISTÂNCIA

Para a pesquisa foram realizados dois levantamentos pelo registro das nuvens coletadas com a câmera de distância. O primeiro foi o levantamento para a obtenção dos resultados iniciais utilizados para a comprovação da metodologia desenvolvida e o segundo foi o levantamento realizado para a comparação com as nuvens obtidas com o *laser scanner*.

4.1.1 Resultados Iniciais

Para verificar a aplicabilidade do método, foi realizado um levantamento preliminar. Este levantamento inicial consistiu de 58 nuvens. Resultando no conjunto de nuvens da figura 9.




FIGURA 9 - REPRESENTAÇÃO DA SALA UTILIZANDO AS 58 NUVENS.
FONTE: O AUTOR

O levantamento da sala foi realizado pelo registro par a par das 58 nuvens. Para a coleta das nuvens, a câmera de distância ficou situada próxima ao centro da sala, a distâncias de 2m a 3m das paredes e objetos imageados. Para a realização do registro foram necessários cuidados para que houvesse a presença de objetos de forma a se obter a convergência adequada com o ICP, pois, neste levantamento, mesmo com uma sobreposição muita alta (acima de 80%) o algoritmo teve dificuldade em obter o alinhamento adequado das nuvens. A maior parte destes casos ocorreu em regiões onde o método foi afetado pela ausência de feições para o registro, nas quais ocorreu a centralização de uma nuvem com a outra devido à influência da uniformidade das paredes, pois, devido ao posicionamento e orientação da câmera, a metade superior das nuvens era normalmente composta apenas de pontos pertencentes aos planos das paredes. Isso pode ser visto na figura 10, que mostra a sala do levantamento. Durante a época do levantamento havia diversos computadores sobre as mesas, que foram posteriormente removidos.



FIGURA 10 - FOTO RECENTE DA SALA LEVANTADA
FONTE: O AUTOR

Porém, em regiões com mais detalhes, textura variada, como no caso das cortinas e janela, e as regiões de canto de parede, o ICP obteve sucesso com mais facilidade. Isso pôde ser notado principalmente na região da cortina, pois, apesar de não haver muitos detalhes, em relação a outras áreas da sala, o ICP convergiu já nas primeiras capturas da câmera.

Pode-se notar, entretanto, um erro de fechamento no ciclo completo da sala, como mostrado na figura 11.




FIGURA 11 - VISTA SUPERIOR DA REPRESENTAÇÃO DA SALA COM AS 58 NUVENS PARA VISUALIZAÇÃO DO ERRO DE FECHAMENTO.
FONTE: O AUTOR

Este erro é resultado do acúmulo de erros ao longo dos registros e é proveniente de distorções presentes nas nuvens geradas pela câmera e de erros de alinhamento do próprio ICP.



FIGURA 12 - PRESENÇA DE DISTORÇÕES INDICADAS PELA COMPARAÇÃO A UMA LINHA RETA.
FONTE: O AUTOR

Na figura 12 pode-se perceber a presença de erro em uma das nuvens. Este erro pode ser causado por diversos fatores: calibração incorreta da câmera, erro devido ao retroespalhamento causado pelos objetos presentes na cena, ou ainda devido ao tempo de integração utilizado, no caso 1000ms. Desta forma, devido à forma como se apresenta esse erro de fechamento, a maior contribuição para ele foi, provavelmente, causada pelo acúmulo de erros presentes nas nuvens e não pelos eventuais erros no registro.

Um estudo demonstrando os efeitos do retroespalhamento pode ser visto com mais detalhes em Jamtsho e Lichti (2010) e influências do tempo de integração nas medidas pode ser visto em Piatti e Rinaudo (2012).

4.1.2 Nuvem gerada para comparação com *laser scanner*

Para comparação com a nuvem de referência obtida com *laser scanner*, um novo levantamento foi realizado, gerando segundo o mesmo processo do levantamento preliminar. Para este levantamento, foram necessárias 22 capturas para recobrir toda a região de interesse do local de estudo. Neste caso a câmera ficou numa região próxima ao computador utilizado.



FIGURA 13 - IMAGEM DA SALA LEVANTADA
FONTE: O AUTOR

A figura 13 é uma foto do local de estudo, para o levantamento alguns outros objetos estavam presentes, além de outros que foram adicionados para a simulação de feições. A posição dos armários e das mesas na sala, porém, permaneceu similar.

Assim como no levantamento preliminar, as capturas foram feitas à distâncias de 2 m a 3 m das paredes do local de estudo. Para cada nuvem, a câmera foi deslocada ou rotacionada no sentido do caminhar. O caminhar acompanhou aproximadamente o alinhamento das paredes, apresentando rotações próximas a zero nas regiões acompanhando os planos das paredes, assim como, da mesma forma, pequenos deslocamentos nas regiões de canto, onde as rotações

foram mais significativas. Quando realizados deslocamentos significativos entre as capturas, estes foram de aproximadamente 40 cm. Na região de canto, principalmente, em que as rotações foram significativas, a variação angular entre as capturas foi de aproximadamente 20°. Na figura 14, é apresentado um esquema mostrando a disposição dos objetos e da câmera no local de estudo.




FIGURA 14 – ESQUEMA DA DISPOSIÇÃO DOS OBJETOS NO LOCAL.
FONTE: O AUTOR

As nuvens obtidas foram então registradas par a par para a obtenção da nuvem contendo a totalidade da região de interesse. Nas figuras 15 e 16, apresenta-se o resultado do registro entre um par de imagens.




FIGURA 15 - VISTA EM PLANTA DO REGISTRO ENTRE DUAS NUVENS DE PONTOS DA CÂMERA. A IMAGEM DA ESQUERDA MOSTRA AS NUVENS ANTES DO REGISTRO, A DA DIREITA APÓS O REGISTRO.
FONTE: O AUTOR




FIGURA 16 - VISTA FRONTAL DO RESULTADO DO REGISTRO ENTRE DUAS NUVENS DA CÂMERA.

FONTE: O AUTOR

Na figura 15 estão representadas duas nuvens (capturas 7 e 8) e o resultado do registro entre elas, visto também na figura 16. Nas imagens, a nuvem a ser registrada está representada em azul e a nuvem de destino em verde. A metade da nuvem utilizada para o registro inicial está representada em vermelho.

Este processo foi aplicado para cada par de nuvens coletados. As transformações para cada nuvem foram salvas e após o registro ter sido efetuado para cada nuvem, as respectivas transformações foram aplicadas às nuvens, obtendo-se a nuvem mostrada na figura 17.




FIGURA 17 - RESULTADO DO REGISTRO COM AS 22 NUVENS DA CÂMERA DE DISTÂNCIA.

FONTE: O AUTOR

A figura 17 comprova que todos os registros par a par foram realizados com sucesso, pois a nuvem final não apresentou incoerências em relação à geometria do objetos levantados. As distorções presentes, porém, em cada nuvem contribuíram de forma que a nuvem gerada por todas as capturas individuais também apresentasse tais distorções. Assim como um aspecto ruidoso devido ao acúmulo de ruídos presentes em cada nuvem. Pode-se observar ainda, a diferença de densidade entre os pontos no centro da nuvem e nas extremidades. Na parte central, devido à maior quantidade de nuvens utilizadas ao longo do processo, há uma maior quantidade de pontos em relação às extremidades, onde houve a presença de pontos de apenas uma ou duas nuvens. Para diminuir essa diferença foi feita a redução da nuvem para uma densidade menor, porém ainda assim a quantidade de pontos presentes no centro permaneceu maior, pois ao realizar uma redução mais severa, utilizando o algoritmo de *voxelgrid* da biblioteca PCL, perde-se informação nas regiões com menor densidade de pontos. Com redução realizada, a quantidade de pontos passou de aproximadamente 800 mil para aproximadamente 500 mil.




FIGURA 18 - VISTA EM PLANTA DO REGISTRO FINAL COM AS 22 NUVENS.
FONTE: O AUTOR

Na figura 18 é possível ver as distorções presentes na nuvem registrada. Apesar da filtragem aplicada individualmente para cada nuvem, a quantidade de ruídos acumulados na nuvem final é perceptível. Estes ruídos surgem devido ao retroespalhamento e ocorrem quando existem dois objetos em profundidades diferentes. Isso é visível na parte central da figura 18, onde há objetos situados próximos à câmera a uma distância de aproximadamente 2 metros da parede ao fundo.

Esse mesmo efeito causa o arredondamento de encontros retos entre feições, como no caso de cantos de paredes, como pode ser notado na área em verde na direita da figura.




FIGURA 19 - ACÚMULO DE RUÍDOS DEVIDO À PRESENÇA DE OBJETOS NA CENA.
FONTE: O AUTOR

A figura 19 mostra, que, mesmo após a filtragem, restaram pontos com ruídos devido ao retroespalhamento. Para a filtragem, assim como para a redução da densidade, evitou-se utilizar valores muitos severos para evitar a remoção excessiva de pontos da nuvem. Ao testar diferentes valores para o parâmetro de filtragem, verificou-se que quando estes ruídos são removidos há uma grande degradação no restante da nuvem, assim, optou-se por manter essa pequena quantidade de ruídos de forma a preservar o restante da nuvem.

4.2 GERAÇÃO DA NUVEM DE REFERÊNCIA

Para gerar a nuvem de comparação foi utilizado o *laser scanner* LEICA HDS 3000, e foi necessário o escaneamento de duas nuvens de pontos a partir de posições diferentes na sala para obter o recobrimento adequado para a comparação com a nuvem de pontos obtida pelo registro das nuvens obtidas com a câmera de distância.

Com os arquivos das duas nuvens obtidos pelo *laser scanner*, foi utilizado uma combinação de dois métodos apresentados no capítulo 3, para gerar a nuvem completa a ser utilizada para avaliar o resultado do registro. Para o alinhamento inicial foi usado o método do SAC-IA, pois a sobreposição entre as duas nuvens era

praticamente completa e apenas umas pequenas regiões com obstruções diferiram de uma para outra, permitindo assim o uso de tal método. Em seguida foi utilizado o ICP para o registro fino entre as nuvens.




FIGURA 20 - NUVENS COLETADAS COM LASER SCANNER.
FONTE: O AUTOR

Na figura 20 são mostradas as duas nuvens escaneadas pelo *laser scanner*: a) e b) são as imagens de cada nuvem e c) uma imagem contendo as duas nuvens em suas orientações iniciais. Na figura 21 é mostrado o resultado do registro destas nuvens.




FIGURA 21 - NUVEM RESULTANTE DO REGISTRO DAS NUVENS *LASER SCANNER*.
FONTE: O AUTOR

As cores representam as duas nuvens de pontos, assim como na figura 20. A separação das cores apresentada é devido à diferença de densidade das nuvens devido ao posicionamento do sensor. Como o espaçamento entre os pontos para ambos os levantamentos foi definido em 1cm à uma distância medida à parede na

região central da sala (onde há a mudança de cor), pode-se então afirmar que a densidade de pontos na nuvem registrada é pelo menos equivalente às partes mais densas das duas nuvens originais, sendo o espaçamento dos pontos da nuvem registrada, portanto, inferior a 1cm.

As duas nuvens escaneadas pelo *laser scanner* possuíam aproximadamente 900 mil pontos cada e, após o registro, a nuvem resultante consistiu de aproximadamente 1,9 milhões de pontos. Para reduzir o esforço computacional necessário para os registros, a densidade da nuvem registrada foi reduzida, diminuindo assim a quantidade de pontos para aproximadamente 1 milhão.

4.3 REGISTRO ENTRE CÂMERA E LASER

Para efetuar o registro entre a nuvem e câmera, foi feita uma alteração dos dados para simular uma situação mais semelhante àquelas a serem encontradas em levantamentos reais.

Como a nuvem gerada com o *laser scanner* apresentou um bom recobrimento de toda a sala escaneada, para simular uma situação de ausência de pontos, foi feita a remoção de alguns pontos da nuvem, gerando assim um vazio na nuvem. A remoção dos pontos foi feita manualmente utilizando o software CloudCompare e os pontos removidos foram pontos pertencentes à uma das paredes (figura 22).




FIGURA 22 - REGIÃO DE PONTOS REMOVIDA PARA SIMULAR A AUSÊNCIA DE PONTOS.
FONTE: O AUTOR

A região de parede, mostrada em vermelho na figura 22, foi removida para reduzir a quantidade de pontos em comum entre as nuvens sendo assim possível a verificação da potencialidade da utilização do ICP em casos de registro de nuvens na presença de vazios, devido a obstruções. A região em questão foi removida por se tratar de uma região plana que será posteriormente utilizada para a avaliação da qualidade do registro.

Para realizar o registro, foi necessário a utilização do algoritmo *Alignment Prerejective*, que utiliza apenas as melhores correspondências para o alinhamento inicial, pois, devido a ausência dos pontos da parede, o algoritmo previamente utilizado para o registro das nuvens do *laser scanner* não apresentou bons resultados.

Utilizando o algoritmo mencionado acima seguido pela execução do ICP foi obtido o registro entre as nuvens da câmera e do *laser scanner*, mostrado na figura 23.




FIGURA 23 - RESULTADO DO REGISTRO ENTRE A NUVEM DA CAMERA E DO *LASER SCANNER*.
FONTE: O AUTOR

Na figura 23 pode-se visualizar o resultado do registro entre a nuvem resultante dos registros das nuvens das câmeras e a nuvem do *laser scanner* com os pontos da parede removidos. Nota-se, que apesar de não apresentar um resultado ótimo, o registro conseguiu aproximar-se à posição correta onde deveria estar situada a nuvem gerada com a câmera.




FIGURA 24 - VISTA EM PLANTA DO RESULTADO DO REGISTRO.
FONTE: O AUTOR

Na figura 24 pode-se ver que, apesar das distorções, o alinhamento teve sucesso. Isso pode ser verificado pelo alinhamento entre as paredes restantes. Pela forma com que o ICP trabalha, pode-se assumir que essas feições tiveram uma contribuição positiva para o resultado adequado do registro, pois são regiões quase planares e com grandes quantidades de pontos alinhados.

4.4 AVALIAÇÃO DA QUALIDADE DO REGISTRO

Após a realização dos registros, é de grande interesse quantificar a qualidade dos dados obtidos como resultados. Para isso, além da análise visual é desejável obter uma quantificação numérica para avaliar essa qualidade. Tal quantificação será obtida de duas maneiras. Através do cálculo da distância ponto a ponto entre as nuvens, utilizando os vizinhos mais próximos, e através do cálculo da distância entre os pontos e o plano gerado pelos pontos da nuvem de referência.

4.4.1 Distância Ponto a Ponto

Uma maneira de avaliar a qualidade da nuvem obtida pelos processos de registro é calcular a distância de cada ponto da nuvem a ser comparada para o ponto mais próximo da nuvem de referência, encontrando, desta forma, a diferença posicional entre as nuvens. Para encontrar esta diferença foi utilizado o programa

CloudCompare. O programa compara duas nuvens e assimila a cada ponto da nuvem comparada um campo relativo à distância ao ponto relativo mais próximo.




FIGURA 25 - NUVEM DA CÂMERA, COLORIDA DE ACORDO COM AS DISTÂNCIAS.
FONTE: O AUTOR

A figura 25 mostra a representação do campo de distâncias sobre a imagem no programa CloudCompare. Para esta comparação foram utilizadas a nuvem registrada obtida com a câmera e a nuvem completa obtida com o *laser scanner*. As cores na imagem representam as diferentes distâncias entre os pontos. A cor azul ciano representa pontos com distâncias de 0 cm, azul de 1 cm, verde de 2,5 cm, amarelo de 5 cm, vermelho de 10 cm e roxo a distância máxima entre as nuvens de 65 cm, seguindo uma rampa de cores gerada com estas cores para as distâncias intermediárias.

De acordo com a figura 25, pode-se perceber que a qualidade da nuvem nas regiões de paredes e algumas outras feições planas foi boa, com a maior parte dos pontos com distâncias entre 0 e 1 cm e em algumas regiões chegando a 3 cm. Nas regiões de ruído e em que distorções são visivelmente distinguíveis são as regiões onde é visto a maioria dos pontos com cores vermelha, roxa e preta.

Tendo-se as distâncias para cada ponto, é possível separá-las em grupos para quantificar a quantidade de pontos. Com isso pode-se quantificar o número de pontos que apresentam as maiores diferenças ou estimar uma diferença média esperada. Isso pode ser visto abaixo a seguir na figura 20 e no quadro 2.




FIGURA 26 - HISTOGRAMA DAS DISTÂNCIAS ENTRE OS PONTOS.
FONTE: O AUTOR

A figura 26 é o histograma representando a distribuição das distâncias entre as duas nuvens gerado pelo próprio programa CloudCompare. Por este histograma nota-se que a maior parte dos pontos apresentou distâncias entre 0 e aproximadamente 5 cm. Através de uma função semelhante do mesmo programa, em que um ajuste estatístico é realizado sobre o histograma, uma distribuição gaussiana ajustada ao histograma obtida a partir dos dados apresentou distância média de 0,042 cm e um desvio-padrão de 0,051 cm. O que indica a proximidade dos pontos das nuvens, assim como os dados apresentados no quadro 2.

QUADRO 2 - QUANTIDADE DE PONTOS SITUADOS A DIFERENTES DISTÂNCIAS.

	<1cm	≥1cm <2cm	≥2cm <3cm	≥3cm <5cm	≥5cm <7,5cm	≥7,5cm <10cm	≥10cm <15cm	≥15cm <30cm	≥30cm
Quantidade de pontos	105831	103199	70728	89555	63268	28170	21090	18852	2449
Razão do Total de Pontos (%)	21,03	20,51	14,06	17,80	12,57	5,60	4,19	3,75	0,49
Acumulado (%)	21,03	41,54	55,60	73,40	85,97	91,57	95,76	99,51	100

FONTE: O AUTOR

O dados do quadro 2 são semelhantes ao histograma apresentado na figura 20, porém com as quantidades numericamente indicadas. Por esta tabela pode-se notar que 85,97% dos pontos obtiveram distâncias menores que 7,5 cm e 73,40% dos pontos distâncias menores que 5 cm. A partir disso poder-se-ia afirmar então que tal qualidade no resultado é de ser esperada.

Porém, como visto anteriormente, a densidade dos pontos da nuvem gerada pela câmera não é distribuída igualmente devido às diferentes quantidades de nuvens utilizadas em cada região, e pode-se notar que justamente na região central é onde está situada a parede com diferenças em torno de 1 cm sendo uma das

regiões com maior densidade de pontos da nuvem. Desta forma, pode-se afirmar que estes resultados obtidos não são completamente fiéis à realidade, pois, para isso, seria necessário que os pontos apresentassem uma distribuição preferencialmente uniforme em toda a nuvem.

4.4.2 Distância Entre Planos

A segunda forma de análise realizada, ao invés da utilização do ponto mais próximo da outra nuvem para o cálculo das distâncias, foi a determinação da equação do plano para certas regiões da nuvem e feito o cálculo da distância ponto a plano para cada ponto realizada.




FIGURA 27 - REGIÕES UTILIZADA PARA A ANÁLISE PONTO A PLANO.
FONTE: O AUTOR

Na figura 27, são mostradas as 13 regiões planas da nuvem selecionadas para comparação. Estas regiões foram selecionadas por consistirem de regiões planas onde a comparação entre planos desejada é possível. A separação dos pontos das regiões de interesse foi feita no software CloudCompare, delimitando os planos de interesse e salvando cada um em um arquivo diferente. Os arquivos das nuvens foram então carregados no MATLAB para o cálculo do plano ajustado e das distâncias entre os pontos. As distâncias dos pontos para os planos foram calculadas, assim como as médias e os desvios-padrão para os treze planos de

interesse selecionados. A análise foi feita separando as regiões por suas características. As regiões 1, 2, 3 e 4 eram sem a degradação devido a distorções e sem a presença de objetos. No quadro 3 são apresentadas as distâncias e desvios-padrão para estas regiões.

QUADRO 3 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 1, 2, 3 E 4.

	1	2	3	4	Total
Distância Média (m)	0,0096	0,0137	0,0159	0,0164	0,0148
desvio-padrão (m)	0,0070	0,0116	0,0130	0,0129	0,0120
Nº de pontos	5578	9476	9803	17263	42120

FONTE: O AUTOR

A partir dos dados do quadro 3, observa-se que para estas regiões o registro obteve bons resultados, com valores na ordem de 1,5 cm. Isso ocorreu, pois estas regiões são regiões de parede, superfície em que há boa resposta ao sensor, e onde não houve o acúmulo de grande quantidade de distorções. Nota-se ainda que o melhor resultado ocorreu na região 1 com distância média inferior a 1 cm. Uma contribuição para isso é o fato desta região, além da ausência quase total de outros objetos em seu entorno, ser composta pelo registro de poucas nuvens, reduzindo assim a quantidade de ruídos presentes devido ao acúmulo destes pelo registro de diversas nuvens.

No quadro 4 são apresentados os valores encontrados para as regiões 5 e 6, que consistem de áreas compostas por superfícies metálicas pouco reflexivas.

QUADRO 4 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 5 E 6.

	5	6	Total
Distância Média (m)	0,0194	0,0243	0,0223
Desvio-padrão (m)	0,0155	0,0184	0,0173
Nº de pontos	7491	10390	17881

FONTE: O AUTOR

As regiões 5 e 6 são semelhantes pois ambas são regiões com moderada quantidade de objetos ao seu redor e, por se tratarem de planos de objetos e não de paredes, podem ter seus valores afetados pelo desnível apresentado ao término de suas extensões. Os resultados obtidos foram piores do que os resultados obtidos para os planos das paredes, com valores para distância superando 2 cm, porém com valores para os desvios-padrão relativamente baixos. A região 5 apresentou

melhores resultados pois se difere da parede por uma pequena diferença e apresenta uma quantidade menor de objetos em seu entorno do que a região 6.

Outro grupo de regiões selecionado foram as regiões 7, 8 e 9 por serem regiões que apresentaram distorções moderadas. Os resultados são apresentados no quadro 5.

QUADRO 5 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 7, 8 E 9.

	7	8	9	Total
Distância Média (m)	0,0325	0,0418	0,0321	0,0358
Desvio-padrão (m)	0,0197	0,0256	0,0224	0,0228
Nº de pontos	10649	11889	9661	32199

FONTE: O AUTOR

A região 7 consiste de uma região de parede, porém apresentou um resultado degradado devido à presença de um objeto diretamente a sua frente, causando um ruído em cada uma das nuvens geradas com a câmera como mostrado anteriormente (figura 13), afetando assim as distâncias calculadas. As regiões 8 e 9 apresentaram diferenças em relação ao plano de referência devido à uma leve curvatura apresentada ao longo das nuvens obtidas com a câmera. Ainda, próximo à região 8, forma-se um canto devido à presença de objetos e, principalmente, de um armário, o que pode ter contribuído para a distorção e consequentemente para a maior diferença encontrada.

As regiões 10 e 11 foram selecionadas por se tratarem de regiões compostas de materiais que se mostraram não favoráveis para a utilização da câmera, onde se notou uma maior presença de ruídos.

QUADRO 6 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 10 E 11.

	10	11	Total
Distância Média (m)	0,0317	0,0374	0,0353
Desvio-padrão (m)	0,0310	0,0315	0,0313
Nº de pontos	5522	9038	14560

FONTE: O AUTOR

Pode-se observar que as distâncias encontradas para estas regiões são similares às encontradas para as regiões 7, 8 e 9, porém os valores para o desvios-padrão encontrados para as regiões 10 e 11 são maiores, o que indica uma maior dispersão dos pontos. A região 10 se trata de um monitor de raios catódicos que afetou a qualidade da medição com a câmera de distância. A região 11 era uma região semelhante às regiões 5 e 6, porém seu resultado foi significativamente pior.

Isso ocorreu devido ao tipo de material do objeto, sendo um metal mais reflexivo que os das regiões 5 e 6, resultando em uma maior presença de ruídos nessa região.

As regiões 12 e 13 foram regiões que apresentaram muita distorção e foram selecionadas para quantificar a influência de tais distorções, o que pode ser visto pelos valores apresentados no quadro 7.

QUADRO 7 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 12 E 13.

	12	13	Total
Distância Média (m)	0,0628	0,1083	0,1043
Desvio-padrão (m)	0,0298	0,0354	0,0350
Nº de pontos	324	3379	3703

FONTE: O AUTOR

A região 12, apesar de ser uma região resultante de apenas uma nuvem, pois foi o local onde foi iniciado o levantamento com a câmera, apresentou um valor alto para a distância obtida, isso ocorreu devido à distorção causada pela presença de outros objetos muito próximos a ela. A região 13 por sua vez, apresentou a pior qualidade com a média das distâncias entre a nuvem e o plano em torno de 10 cm. Essa diferença é visível na figura 18, mostrada anteriormente. A maior influência para essa diferença é o arredondamento do canto da nuvem gerada com a câmera. Além disso, deve-se considerar que esta região do levantamento é separada da sala por vidro, que afeta também a qualidade dos resultados.

As regiões com grande quantidade de ruídos e distorções são facilmente identificáveis e consistem, normalmente, de uma pequena porção da totalidade dos pontos situada em determinadas regiões. Desta forma pode-se assumir que esses pontos podem ser removidos ou capturas adicionais podem ser feitas para minimizar a sua presença, o que pode ser alcançando por um bom planejamento para o levantamento ou remoção manual dos ruídos. No quadro 8 são apresentados a distância média e desvio-padrão, sem considerar as regiões com grande quantidade de erros.

QUADRO 8 - DISTÂNCIAS E DESVIOS-PADRÃO PARA REGIÕES 1 A 11.

	1-4	5-6	7-9	10-11	Total
Distância Média (m)	0,0148	0,0223	0,0358	0,0353	0,0252
Desvio-padrão (m)	0,0120	0,0173	0,0228	0,0313	0,0199
Nº de pontos	42120	17881	32199	14560	106760

FONTE: O AUTOR

Deste quadro pode-se observar, portanto, que a qualidade média esperada seja em torno de 3 cm para regiões favoráveis na presença de áreas com distorções moderadas. Ainda assim, o erro destas áreas com pode ser superior a 3 cm.

Porém, como grande parte das diferenças é proveniente de erros sistemáticos do sensor, para avaliar a qualidade esperada do registro, devem ser avaliadas as regiões menos influenciadas por erros e com menor quantidade de distorções. Por isso, no quadro 9, são consideradas somente as regiões 1 a 6, aquelas com menor influência de erros.

QUADRO 9 - DISTÂNCIAS MÉDIAS E DESVIOS-PADRÃO PARA REGIÕES 1 A 6.

	1-4	5-6	Total
Distância Média (m)	0,0148	0,0223	0,0170
Desvio-padrão (m)	0,0120	0,0173	0,0138
Nº de pontos	42120	17881	60001

FONTE: O AUTOR

O quadro 9 indica a distância média para as regiões com pouca presença de ruídos e distorções. Como se pode observar, nessas condições a distância média a ser esperada é em torno de 2 cm, indicando um resultado satisfatório do registro.

Pelos valores apresentados, percebe-se que as distâncias calculadas ponto a plano são coerentes às distâncias obtidas pelo ponto a ponto, como pode ser verificado ao se observar na figura 25 as áreas referentes às 13 regiões selecionadas.

5 CONCLUSÕES

Esta pesquisa foi realizada com o intuito de mostrar a qualidade de uma nuvem de pontos gerada com câmera de distância através de um processo de registro geométrico e o resultado da sua integração a uma nuvem obtida com *laser scanner*. Ao se verificar a viabilidade e qualidade esperada com a aplicação deste processo, novas maneiras de se realizar levantamentos tridimensionais são disponibilizadas seja utilizando um mesmo tipo de sensor ou diferentes sensores. Baseando-se nos resultados e análises apresentados anteriormente algumas conclusões podem ser feitas.

Primeiramente para a pesquisa foram estudados alguns métodos de registro geométrico e sua forma de aplicação, ou seja, as situações em que são aplicáveis. Com isso foi possível definir a metodologia a ser aplicada para obter os resultados apresentados.

Ainda na fase inicial da pesquisa, alguns experimentos utilizando a câmera foram realizados e, com seus resultados, foi possível desenvolver a forma de registro descrita na metodologia para as nuvens geradas por suas imagens de distância. O levantamento preliminar de uma sala utilizando o método foi realizado para comprovar sua viabilidade e através desse levantamento foram notadas algumas distorções presentes nas nuvens geradas pela câmera de distância. Ainda assim pode-se verificar que o método utilizado conseguiu realizar o registro das nuvens adequadamente, apesar do local de estudo utilizado não ser favorável devido à pouca presença de objetos e feições significativas para o registro.

O segundo levantamento, para a comparação com o *laser scanner*, foi realizado da mesma maneira, porém, devido à maior quantidade de objetos presentes no local o registro alcançou bons resultados com mais facilidade. Como a área levantada consistiu de apenas um canto de uma sala, o erro notado no experimento inicial não foi significativo. Porém, justamente devido à presença dos objetos, com grande diferença de profundidade para o fundo da cena, notou-se a presença de muitos ruídos causados pelo retroespalhamento gerado por eles. Estes ruídos não afetaram o registro entre as nuvens da câmera, pois com a filtragem eles foram bastante reduzidos, porém o acúmulo dos vestígios de cada nuvem foi perceptível na nuvem registrada resultante.

Os alinhamentos iniciais pelos métodos baseados em RANSAC se mostraram eficientes quando utilizados os parâmetros adequados. O registro entre as nuvens do *laser scanner* apresentou resultados mais consistentes mesmo com a entrada de diferentes parâmetros, isso se dá devido à sobreposição quase total e densidades e precisões semelhantes entre as nuvens. Porém o alinhamento inicial da nuvem gerada com a câmera de distância foi mais difícil de ser corretamente encontrado, pois devido à presença de ruídos na nuvem gerada com a câmera, os parâmetros utilizados afetaram significativamente o resultado do alinhamento.

O resultado do registro realizado entre a nuvem obtida com a câmera e a nuvem do *laser scanner* com parte dos dados removidos indica que o ICP converge adequadamente em nuvens sem recobrimento total, mesmo na presença de ruídos e pequenas distorções, desde que fornecido um bom alinhamento inicial. Como esperado, por serem utilizados métodos bastantes difundidos na área de registro geométrico, os resultados obtidos foram adequados e mostram que o processo do registro é aplicável para inúmeras situações, incluindo dados obtidos de diferentes sensores e sob presença de ruídos.

Em relação à qualidade final alcançada pelo processo de registro, pode-se afirmar que foi parcialmente satisfatória. As regiões planas foram os locais onde foi possível alcançar os melhores resultados e, ainda assim, houve uma presença considerável de ruídos. Em alguns objetos presentes na cena e bordas, a qualidade do registro foi insatisfatória, sendo o erro visualmente perceptível. O principal fator para isso foram as nuvens geradas pela câmera de distância, onde em regiões com presença de objetos, ou de grandes diferenças de profundidade, a quantidade de ruídos é considerável, degradando assim a qualidade do produto gerado antes mesmo do registro ser efetuado. Apesar disso, os resultados obtidos mostram que utilizando-se a metodologia apresentada pode-se esperar erros médios de até 2 cm, dependendo da cena a ser mensurada.

Assim, pode-se concluir que a metodologia descrita é eficiente e a câmera de distância pode ser utilizada para realizar levantamentos tridimensionais ou complementar tais levantamentos. Deve-se considerar, porém, a diferença de qualidade nos dados obtidos com este tipo de sensor pois a diferença de qualidade nos dados dificulta o registro e afeta diretamente a qualidade do resultado mesmo que este seja realizado isento de erros.

5.1 CONSIDERAÇÕES E RECOMENDAÇÕES

Para realizar esta pesquisa as capturas com a câmera de distância foram realizadas um quadro por vez, como imagens, e posteriormente registradas. O sensor possibilita, porém, a captura contínua, como um vídeo, da nuvem de pontos. Essa forma de captura pode apresentar resultados diferentes dos obtidos através da metodologia aplicada e pode, portanto, ser averiguada.

A presença de ruídos e distorções nas nuvens geradas com a câmera de distância foi significativa durante a pesquisa. Para reduzir sua influência, alguns trabalhos foram feitos buscando quantificar e modelar estes erros (JAMTSO e LICHTI (2010); KAREL *et al.* (2010)). Desta forma, pode-se buscar a modelagem destes erros para gerar um produto com melhor qualidade para o registro.

As nuvens geradas pela câmera foram obtidas pela projeção ortogonal dos pontos da imagem utilizando os parâmetros da calibração da câmera, porém existe a possibilidade das coordenadas dos pontos não terem sido fiéis às coordenadas reais dos objetos, ocasionando uma pequena diferença de escala. Isso pode ser averiguado realizando testes com objetos de medidas conhecidas e caso necessário uma nova calibração da câmera realizada.

Além disso, o registro das diversas nuvens da câmera resultou em densidades diferentes ao longo da nuvem, uma densidade alta nas regiões com sobreposição de diversas nuvens e baixa nas regiões formadas por poucas nuvens. Portanto, a busca de uma distribuição mais adequada da densidade para toda a nuvem é recomendada para verificar como tal diferença afeta o registro, além de melhorar a avaliação da qualidade dos resultados.

REFERÊNCIAS

- BESL, Paul J.; MCKAY, Neil D. **A Method for Registration of 3-D Shapes**. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 14, n. 2, 1992, p. 239-256.
- BIBER, P.; STRAßER, W. **The normal distributions transform: a new approach to laser scan matching**. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003), vol.3, Las Vegas, 2003, p. 2743-2748
- BRUNNSTRÖM, K.; STODDART, A. J. **Genetic Algorithms for Free-Form Surface Matching. Pattern Recognition, 1996**. Proceedings of the 13th International Conference on, vol.4, Vienna, 1996, p. 689-693.
- BUCH, A.G.; KRAFT, D.; KAMARAINEN, J.-K.; PERERSEN, H.G.; KRUGER, N., **Pose estimation using local structure-specific shape and appearance context**, IEEE International Conference on Robotics and Automation, Karlsruhe, 2013, p. 2080-2087.
- CARMICHAEL, O.; HUBER, D.; HEBERT, M. **Large data sets and confusing scenes in 3-D surface matching and recognition**, Proceedings of Second International Conference on 3-D Digital Imaging and Modeling, Ottawa, 1999, p.358-367.
- CHEN, C.; STAMOS, I. **Semi-automatic range to range registration: a feature-based method**. 3DIM 2005. Fifth International Conference on 3-D Digital Imaging and Modeling, Ottawa, 2005, p. 254,261.
- CHEN, C.S.; HUNG, Y.P.; CHENG, J.B. **A fast automatic method for registration of partially-overlapping range images**, Sixth International Conference on Computer Vision, Bombay, 1998, p. 242-248.
- CHEN, C.S.; HUNG, Y.P.; CHENG, J.B. **RANSAC-based DARCES: a new approach to fast automatic registration of partially overlapping range images**. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 21, no. 11, 1999, p. 1229-1234.
- CHEN, Y.; MEDIONI, G. **Object modelling by registration of multiple range images**. Image and Vision Computing, vol. 10, no. 3, 1992, p. 145-155.
- CHETVERIKOV, D.; SVIRKO, D.; STEPANOV, D.; KRSEK, P. **The Trimmed Iterative Closest Point Algorithm**. Proceedings. 16th International Conference on Pattern Recognition, vol. 3, Quebec City, 2002, p. 545-548.
- CHUA, C.S.; JARVIS, R. **Point Signatures: A New Representation for 3D Object Recognition**. International Journal of Computer Vision, vol. 25, n. 1, 1997, p. 63-85.
- CHUNG, D.H.; YUN, I.D.; LEE, S.U. **Registration of Multiple-Range Views Using the Reverse-Calibration Technique**. Pattern Recognition, vol. 31, n. 4, 1998, p. 457-464.

DROESCHEL, D.; HOLZ, D.; STUCKLER, J.; BEHNKE, S. **Using Time-of-Flight Cameras with Active Gaze Control for 3D Collision Avoidance.** IEEE International Conference on Robotics and Automation, Anchorage, Alaska, 2010.

GELFAND, N.; IKEMOTO, L.; RUSINKIEWICZ, S.; LEVOY, M. **Geometrically stable sampling for the ICP algorithm.** Proceedings of the Fourth International Conference on 3-D Digital Imaging and Modeling. Banff, 2003, p. 260-267.

GODIN, G.; RIOUX, M.; BARIBEAU, R. **Three-dimensional Registration Using Range and Intensity Information.** Proceedings of SPIE: Videometrics III, Vol. 2350, 1994, p. 279-290.

GREENSPAN, M.; GODIN, G. **A nearest neighbor method for efficient ICP.** Third International Conference on 3-D Digital Imaging and Modeling, Quebec City, 2001, p. 161-168.

HUBER, D.; HEBERT, M. **A New Approach to 3-D Terrain Mapping.** Proceedings of the 1999 IEEE/RSJ International Conference on Intelligent Robotics and Systems (IROS '99), Kyongju, 1999, p. 1121-1127.

JAMTSO, S.; LICHTI, D. D. **Modelling Scattering Distortion in 3D Range Camera.** International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 18, part 5, Newcastle upon Tyne, 2010. p. 299-304.

JOHNSON, A.E. **Spin-Images: A Representation for 3-D Surface Matching.** 288 p. (Dissertação, Robotics Institute, Carnegie Mellon University for the degree of Doctor of Philosophy in the field of Robotics). Carnegie Mellon University, E.U.A., 1997.

JOHNSON, A.E.; HEBERT, M. **Using spin images for efficient object recognition in cluttered 3D scenes.** IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 21, no. 5, 1999, p. 433-449.

JOST, T.; HUGLI, H. **A multi-resolution scheme ICP algorithm for fast shape registration,** First International Symposium on 3D Data Processing Visualization and Transmission, Padova, 2002, p. 540-543.

KAREL, W.; GHUFFARB, S.; PFEIFERB, N. **Quantifying The Distortion Of Distance Observations Caused By Scattering In Time-of-flight Range Cameras.** International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. 18, part 5, Newcastle upon Tyne, 2010. p. 316-321.

LANGE, R. **3D Time-of-Flight distance measurement with custom solid-state image sensors in CMOS/CCD-technology.** 205 p. (Dissertação, Department of Electrical Engineering and Computer Science at University of Siegen for the degree of Doctor of Technical Sciences). University of Siegen, Alemanha, 2000.

MASUDA, T.; SAKAUE, K.; YOKOYA, N. **Registration and integration of multiple range images for 3-D model construction**. Proceedings of the 13th International Conference on Pattern Recognition, vol. 1, Vienna, 1996, p. 879-883.

MASUDA, T. **Generation of geometric model by registration and integration of multiple range images**. Proceedings of the Third International Conference on 3-D Digital Imaging and Modeling, Québec City, 2001, p. 254-261.

MASUDA, T. **Object shape modeolling from multiple range images by matching signed distance fields**. Proceedings of the First International Symposium on 3D Data Processing Visualization and Transmission, Padova, 2002, p. 439-448.

MAY, S.; DROESCHEL, D.; HOLZ, D.; FUCHS, S.; MALIS, E.; NÜCHTER, A.; HERTZBERG, J. **Three Dimensional Mapping with Time-of-Flight Camera**. Journal of Field Robotics, vol. 26, n. 11-12, 2009, p. 934-965.

MITRA, N.J.; GELFAND, N.; POTTMANN, H.; GUIBAS, L. **Registration of Point Cloud Data from a Geometric Optimization Perspective**. SGP '04 Proceedings of the 2004 Eurographics/ACM SIGGRAPH symposium on Geometry processing, Nice, 2004, p. 23-32.

OLIVEIRA, A.A.A. **Modelagem Tridimensional de Superfícies Utilizando Imagem TOF: Estudo com a Câmara PMD CamCube 2.0**. 127 p. – (Dissertação mestrado – Programa de Pós-Graduação em Ciências Geodésicas). Universidade Federal do Paraná, Curitiba, 2011.

PIATTI, D.; RINAUDO, F. **SR-4000 and CamCube 3.0 Time of Flight cameras: Tests and Comparison**. Remote Sensing, no. 4, 2012, p. 1069-1089.

PMD Technologies. **PMD [vision]®CamCube 3.0**. 4p. Datasheet n. 20100601. Siegen, 2010. Disponível em: <http://web.archive.org/web/20110408210644/http://www.pmdtec.com/fileadmin/pmdtec/downloads/documentation/datenblatt_camcube3.pdf>. Acesso em: 16/10/ 2013.

RUSINKIEWICZ, S.; LEVOY, M., **Efficient variants of the ICP algorithm**. Proceedings. Third International Conference on 3-D Digital Imaging and Modeling, Quebec City, 2001, p. 145-152.

RUSU, R.B. **Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments**. 260 p. (Dissertação, Department of computer science at the Technical University of Munich for the degree of Doctor of Natural Sciences). Technischen Universität München, Alemanha, 2009.

RUSU, R.B.; BLODOW, N.; BEETZ, M., **Fast Point Feature Histograms (FPFH) for 3D registration**, IEEE International Conference on Robotics and Automation, Kobe, 2009, p. 3212-3217.

SALVI, J.; MATABOSCH, C.; FOFI, D.; FOREST, J. **A review of recent range image registration methods with accuracy evaluation**. Image and Vision Computing, vol. 25, n. 5, 2007, p. 578-596.

SEGAL, A.; HAEHNEL, D.; THRUN, S. **Generalized-ICP**. Proceedings of Robotics: Science and Systems, Seattle, 2009.

SEHGAL, A.; CERNEA, D.; MAKAVEEVA, M. **Real-Time Scale Invariant 3D Range Point Cloud Registration**. Lecture Notes in Computer Science, vol. 6111, 2010, p. 220-229.

SHARP, G.; LEE S.; WEHE, D. **ICP registration using invariant features**, IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 24, n. 1, 2002, p. 90-102.

STAMOS, I.; LEORDEANU, M. **Automated feature-based range registration of urban scenes of large scale**. Proceedings of 2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol.2, Madison, 2003, p. 555-561.

TAREL, J.P.; CIVI, H.; COOPER, D.B. **Pose Estimation of Free-Form 3D Objects without Point Matching using algebraic surface Models**. Proceedings of IEEE Workshop Model Based 3D Image Analysis, Mumbai, 1998, p. 13-21.

TRUCCO, E.; FUSIELLO, A.; ROBERTO, V. **Robust motion and correspondences of noisy 3-D point sets with missing data**, Pattern Recognition Letters, vol. 20, n. 9, 1999, p. 889-898.

TURK, G.; LEVOY, M. **Zippered polygon meshes from range images**. Proceedings of the 21st annual conference on computer graphics and interactive techniques. New York, 1994, p. 311-318.

WEIK, S. **Registration of 3-D partial surface models using luminance and depth information**. Proceedings of the International Conference on Recent Advances in 3-D Digital Imaging and Modeling, Ottawa, 1997, p. 93-100.

WEINGARTEN, J.W.; GRUENER, G.; SIEGWART, R. **Probabilistic plane fitting in 3D and an application to robotic mapping**. Proceedings. IEEE International Conference on Robotics and Automation, vol. 1, New Orleans, 2004, p. 927-932.

WYNGAERD, J.V.; GOOL, L.V. **Automatic Crude Patch Registration: Toward Automatic 3D Model Building**. Computer Vision and Image Understanding, vol. 87, n. 1-3, 2002, p. 8-26.

ZINSSER, T.; SCHNIDT, H.; NIERMANN, J. **A refined ICP algorithm for robust 3-D correspondences estimation**, International Conference on Image Processing, vol. 2, Barcelona, 2003, p. 695–698.